

APRENDIZAGEM NA PERSPECTIVA DO CÉREBRO BAYESIANO

LEARNING FROM THE PERSPECTIVE OF THE BAYESIAN BRAIN

APRENDIENDO DESDE LA PERSPECTIVA DEL CEREBRO BAYESIANO

Mirela Cunha Cardoso Ramacciotti¹
Maria Luiza Iennaco²

Resumo

Esta revisão narrativa apresenta o construto teórico do Cérebro Bayesiano para o campo da aprendizagem. O objetivo é contribuir para a ampliação e consolidação do entendimento de processos do aprender. A revisão apresenta o histórico do arcabouço do Cérebro Bayesiano, a definição de sua nomenclatura básica bem como esclarecimentos acerca dos conceitos fundantes, como os do processamento preditivo e da inferência bayesiana. Para exemplificação da aprendizagem, analisamos construtos na área de como se aprende a linguagem oral a fim de oferecer maior clareza na exploração das possibilidades de entendimento que o arcabouço oferece dentro do método científico. Isso implica na observação e experimentação de fenômenos fundamentados em um princípio que integra percepção, cognição e ação. Essa nova abordagem pode alimentar o ciclo de hipóteses e empirismo sobre o qual se baseia a ciência para que evidências científicas na área da aprendizagem possam estar alinhadas com os recentes avanços no entendimento do funcionamento cerebral.

Palavras-chave: Aprender; Cérebro Bayesiano; Inferência; Processamento Preditivo; Teorema de Bayes.

Abstract

This narrative review presents the theoretical construct of the Bayesian Brain for the field of learning. The objective is to contribute to the expansion and consolidation of learning processes. The review presents the history of the Bayesian Brain framework and the definition of its basic nomenclature. It also makes explicit its core concepts, such as predictive processing and Bayesian inference. To exemplify learning, we analyzed constructs related to how oral language is learned for greater clarity in the exploration of the possibilities of understanding that the framework enables within the scientific method. This implies the observation and experimentation of phenomena based on a principle that integrates perception, cognition and action. This new approach can feed the cycle of hypotheses and empiricism on which science is based so that scientific evidence in the area of learning can be aligned with recent advances in the understanding of brain functioning.

Keywords: Learn; Bayesian Brain; Inference; Predictive Processing; Bayes' Theorem.

Resumen

Esta revisión narrativa presenta el constructo teórico del cerebro bayesiano para el campo del aprendizaje. El objetivo es contribuir a la ampliación y consolidación de la comprensión de los procesos de aprendizaje. La revisión presenta la historia del marco del cerebro bayesiano, la definición de su nomenclatura básica, así como aclaraciones sobre los conceptos fundamentales, como el procesamiento predictivo y la inferencia bayesiana. Para ejemplificar el aprendizaje, analizamos los constructos en el área de cómo se aprende el lenguaje oral con el fin de ofrecer una mayor claridad en la exploración de las posibilidades de comprensión

¹Doutora em Psicologia pela Universidade de São Paulo (USP) e em Fonoaudiologia pela Universidade Federal de São Paulo (UNIFESP). Docente externa no Instituto de Psicologia (USP). Orcid: <https://orcid.org/0000-0002-3109-8376> Lattes: <http://lattes.cnpq.br/3658640400115779> E-mail: neuroeducamente@gmail.com

²Doutoranda em Filosofia pela Universidade de São Paulo (USP) e pela Universidade do Porto (UPORTO, Portugal). Faculdade de Filosofia, Letras e Ciências Humanas (USP). Instituto de Filosofia (UPORTO). Orcid: <https://orcid.org/0000-0002-5407-4852> Lattes: <http://lattes.cnpq.br/7275202884165313> E-mail: marialuiza_vasconcelos@usp.br

que el marco permite dentro del método científico. Esto implica la observación y experimentación de los fenómenos a partir de un principio que integra la percepción, la cognición y la acción. Este nuevo enfoque puede alimentar el ciclo de hipótesis y empirismo en el que se basa la ciencia para que la evidencia científica en el área del aprendizaje pueda alinearse con los avances recientes en la comprensión del funcionamiento del cerebro.

Palabras clave: Aprender; Cerebro Bayesiano; Inferencia; Procesamiento Predictivo; Teorema De Bayes.

Introdução

Aprender é, de uma perspectiva biológica, essencialmente uma atividade neural (Dehaene, 2022; Koizumi, 2008). É por meio de processos de ordem biológica, como moléculas (e.g., ATP), conexões sinápticas (e.g., transmissão sináptica para propagação do estímulo), redes neurais (e.g., como as que se formam entre e dentro os hemisférios cerebrais) que o comportamento da aprendizagem emerge. Entender como isso se dá envolve diferentes áreas, como a neurobiologia ou neurociência básica (neurociência molecular, neuroquímica, neurofisiologia) e aplicada em diálogo com a psicologia e a educação. No entanto, para que da compreensão possamos avançar para o entendimento do processo de aprendizagem, em diferentes instâncias de verificação, através de experimentos concebidos para analisar componentes específicos do aprender (como processos mnemônicos e atencionais), há que se ter um arcabouço teórico plausível. Isso se faz necessário para testar hipóteses, conceber experimentos e discutir resultados. O objetivo maior é assegurar processos científicos que possam nos fornecer métricas adequadas para evidenciar compreensão em bases compartilhadas de entendimento para o avanço do conhecimento.

A presente revisão insere-se no campo dos processos de Ensino-Aprendizagem. Foi feita por meio de uma seleção de estudos com base em sua relevância, rigor e escopo utilizando-se bases como PubMed e Google Scholar. Note-se que essa abordagem metodológica é conveniente para sintetizar descobertas. Enfatizamos que pode não captar a amplitude das pesquisas disponíveis e que se encontra sujeita a vieses de adequação. O objetivo desta revisão é apresentar um modelo teórico relativamente recente, pois se formou como tal no século XXI, após uma longa trajetória de ideias basilares dispersas em tempos, lugares e áreas distintas. Tais ideias, tomadas em conjunto, propõem um raciocínio lógico para a operação que o cérebro realiza ao consubstanciar ações em comportamento, tal qual o comportamento que se exprime em aprendizagem. Faremos a revisão desse tema, i.e., o Cérebro Bayesiano, elencando ideias elementares e seu

conjunto de implicações. Apresentamos na sequência o conceito central junto a seus mecanismos básicos. Prosseguimos com seu histórico de desenvolvimento como arcabouço teórico para percepção, ação e cognição (Seth, 2015) que propiciou um novo olhar sobre percepção e aprendizagem, brevemente analisados. Finalizamos com uma apreciação de exemplos de aprendizagem da área da aquisição da linguagem, na perspectiva do arcabouço do Cérebro Bayesiano.

Apresentação Conceitual

O Cérebro Bayesiano, muitas vezes considerado um novo paradigma das neurociências cognitivas (Friston & Frith, 2015; Hipólito & Kirchoff, 2023; Piekarski, 2021), apresenta-se como uma alternativa para a ideia de que o cérebro é uma esponja ou um filtro passivo de sensações. A ideia central é o cérebro como um órgão estatístico que modela o *sensorium* - ou conjunto de órgãos sensoriais de aferência perceptual - do organismo. Assim considerado, o cérebro geraria hipóteses sobre as causas ocultas, i.e., não acessáveis nem disponíveis, do mundo. Tais hipóteses seriam constantemente testadas perante as evidências sensoriais (ou seja, os efeitos dessas causas que nossos sensores ou órgãos dos sentidos captaram), com o objetivo de atualizar e otimizar as “crenças”, i.e., nossos modelos internos e comportamentos como organismos, seguindo a formalidade da estatística bayesiana. Por esse motivo e conforme veremos, o cérebro nesse contexto realizaria inferência bayesiana aproximada (Thornton, 2017). Além disso, o arcabouço teórico do Cérebro Bayesiano implica em uma nova forma de compreender e descrever múltiplos aspectos da cognição, tais como a percepção, atenção, aprendizagem, propondo-se a descrever o comportamento (Brown, Friston, & Bestmann, 2011; Brown & Brüne, 2012; Clark, 2013; 2016; Friston, 2003; 2005; Friston & Kiebel, 2009).

Em termos gerais, o Cérebro Bayesiano propõe que a nossa percepção é indireta pois que majoritariamente constituída de informações que possuímos do meio percebido. Isso implica a existência de um véu sensorial entre nós e o meio externo. Esse véu costuma ser compreendido em termos estatísticos (através do construto do Cobertor de Markov³) (Kirchhoff & Kiverstein, 2018). A atenção, nesse contexto, serve como um

³Na literatura do Cérebro Bayesiano, o conceito de Cobertor de Markov, tradução direta do termo em inglês *Markov Blanket*, é utilizado para descrever a barreira que separa um organismo do seu ambiente. Michael

ponderador-gargalo cujo papel é garantir que as melhores evidências sensoriais internas e externas (isto é, aquelas que melhor compactuam com os nossos modelos) sejam captadas pelos nossos órgãos sensoriais (Brown, Friston, & Bestmann, 2011). Em outras palavras, prestamos atenção naquilo que já nos prendeu a atenção - ao menos em parte. Os comportamentos também serão orientados à atualização e otimização dos nossos modelos, tanto para autorrealizá-los quanto para refinar a amostra sensorial. Assim posto, as formas de aprendizagem no Cérebro Bayesiano emergem da otimização dos parâmetros desses modelos em várias escalas espaço-temporais (Friston *et al.*, 2016). Por exemplo, quando se aprende a dirigir um veículo, os parâmetros, isto é, as instruções (do seu próprio corpo – movimentos, atenção etc. como também do próprio corpo para com o veículo – onde colocar as mãos e os pés) do que se deve fazer para ligá-lo e iniciar um trajeto serão, no início, rígidas e irão necessitar muita atenção e cognição do condutor. Após um período de práticas em diferentes espaços, o condutor otimiza seus parâmetros, de modo que todas as instruções de como ligar e iniciar um trajeto com o veículo sejam automáticas e talvez até inconscientes, economizando energia e cognição do condutor.

Algumas formulações do Cérebro Bayesiano costumam partir do chamado Princípio da Energia Livre (no inglês *Free Energy Principle*), cujo imperativo para o organismo consiste em minimizar a surpresa (chamada de energia livre variacional, i.e., as situações não previstas) e maximizar sua própria evidência no mundo ao manter seus modelos e constituição orgânica otimizados (Friston, 2009). Além disso, os aspectos centrais dos modelos bayesianos para o cérebro foram desenvolvidos a partir da noção de inferência inconsciente (Helmholtz, 2000/1924-5) para que fosse possível formalizar a chamada inferência bayesiana aproximada (i.e., imprecisa) e hierárquica (i.e., que obedece a uma organização sequenciada por níveis e etapas) sobre as causas das sensações e como essas inferências orientam nossa percepção e comportamento (Friston & Frith, 2015).

Kirchoff e Julian Kiverstein (2018) explicam que essa ideia tem suas raízes na estatística (Pearl, 1988) e consiste em uma barreira, ou membrana, de ordem estatística que divide os estados internos (do organismo) dos estados externos (do ambiente) através de estados ativos (ações) e estados sensoriais (informações do ambiente). Dessa forma, os estados internos e externos são conectados por meio de estados ativos e sensoriais. Esse conceito nos permite visualizar e calcular a interação entre um organismo e seu ambiente em todas as escalas de análise, desde uma célula até um organismo completo, considerando o aninhamento de múltiplos Cobertores de Markov em sistemas como o nosso (para mais detalhes sobre o Cobertor de Markov, consulte Kirchoff & Kiverstein, 2018; Hipólito *et al.* 2021).

É válido ressaltar a pluralidade teórica e de modelagens que compõem o arcabouço do Cérebro Bayesiano, uma vez que ele pode também ser chamado de “cérebro preditivo”, assim como “inferência bayesiana” e “atualização de crença bayesiana”, podem ser simplesmente chamadas de “processamento preditivo”. Inclusive, o último abarca modelos mais próximos do Cérebro Bayesiano como a “codificação preditiva”. Não é nosso objetivo aqui analisar a terminologia, mas apenas esclarecer a existência desse panorama e justificar a nossa escolha do “Cérebro Bayesiano” como arcabouço teórico, por ser mais amplo e didático.

Referencial Teórico

Histórico

O histórico do Cérebro Bayesiano no ocidente europeu pode ser traçado a partir do século XVIII, quando a filosofia e a matemática estavam desenvolvendo os principais construtos e ideias que são utilizados nas concepções atuais do Cérebro Bayesiano. O termo “bayesiano” vem de Thomas Bayes, um matemático protestante inglês que viveu entre 1701 e 1761. Ele se debruçou sobre o cálculo de parâmetros de probabilidade (Kawano & Paiva, 2023). Contudo, apesar de pertencente à elite acadêmica – notadamente por sua admissão na *Royal Society* - da Inglaterra do século XVIII - Bayes faleceu sem divulgar seu trabalho (Kawano & Paiva, 2023).

Essa tarefa coube a Richard Price, filósofo e político inglês que viveu entre 1723 e 1791, e foi responsável por tornar público, perante registro nos anais da *Royal Society*, o trabalho de Thomas Bayes (Kawano & Paiva, 2023), intitulado *An Essay towards Solving a Problem in the Doctrine of Chances* (em português “Um Ensaio para Solucionar um Problema na Doutrina das Probabilidades”). O trabalho versava sobre probabilidades e distribuição binomial. Em termos gerais, essa distribuição é utilizada para determinar a probabilidade de certa ocorrência acontecer dentro de um evento com sistema fechado, como por exemplo, experimentos repetidos com dois possíveis resultados: sim ou não; cara ou coroa; sucesso ou fracasso; e outros pares similares. Em sua análise matemática, Bayes formalizou os conceitos de probabilidade condicionada (Kawano & Paiva, 2023).

Independentemente de Bayes, Pierre Simon Laplace, em sua obra *Theorie Analytique des Probabilités* (em português “Teoria Analítica das Probabilidades”)

publicada em 1821, trabalhou no mesmo tema e acabou estendendo as ideias de Bayes (Kawano & Paiva, 2023). Ele usou a ideia de probabilidade condicionada para formular a relação de uma probabilidade posterior atualizada dado as evidências. Assim, o Teorema de Bayes - que poderia ser de Price-Bayes ou de Bayes-Laplace – nos permite calcular a probabilidade de uma causa, dado seus efeitos. Esse teorema foi desenvolvido na estatística bayesiana e é muito utilizado em várias áreas do conhecimento.

Intuitivamente, o teorema auxilia na elaboração de inferência dos resultados, em contextos com algum grau de incerteza, ao descrever a probabilidade de um evento ocorrer ou já ter ocorrido, dado o conhecimento prévio das condições que possivelmente estão relacionadas ao mesmo evento. Em outras palavras, o Teorema de Bayes nos ajuda a achar a melhor hipótese para uma causa dada a possibilidade dessa causa acontecer e o conhecimento de seus acontecimentos prévios. Isso se formaliza através desta equação:

Equação 1. Teorema de Bayes.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Onde A e B são eventos, podendo ser, especificamente, **hipóteses** (A) e **evidências** (B). $P(A|B)$ consiste na probabilidade condicional. Isto é, a probabilidade do evento A ocorrer dado que B é verdadeiro. Pode-se chamar também de probabilidade **posterior** de A dado B. $P(B|A)$ consiste na **verossimilhança**. Ela também é uma probabilidade condicional, só que do evento B ocorrer dado que A é verdadeiro. Assim, seria a verossimilhança associada a A. $P(A)$ e $P(B)$ são as probabilidades de observar A e B sem qualquer condição dada, sendo chamados, respectivamente, de probabilidade anterior (**prior**) e probabilidade marginal. Note-se que $P(B)$ funciona como um fator de normalização (probabilidade marginal da evidência) que garante que as probabilidades posteriores somem 1 apenas quando consideramos todas as hipóteses possíveis.

Isso é importante para a apreciação do processo de aprendizagem pois, conforme veremos, no arcabouço teórico do Cérebro Bayesiano considera-se o conhecimento prévio de cada indivíduo - o qual parte de pontos sempre diferentes dada a diferença de pré-disposições genéticas, de temperamento e de contexto.

Ainda no século XVIII, no campo da filosofia, David Hume (1711–1776) alertava para o “problema da indução” formulado em relação à percepção. Isto é, ele argumentou que é impossível nossas inferências (ou hipóteses) causais estarem plenamente corretas. Isso se dá porque o único modo de inferirmos algo com total certeza seria por meio de inferências dedutivas. Contudo, as inferências bayesianas são indutivas e, levando em conta que a passagem direta da indução para a dedução é inviável, o resultado absoluto das inferências bayesianas sempre será acompanhado de um certo grau de incerteza (Hume, 1748).

Immanuel Kant, filósofo iluminista que também viveu no século XVIII, fascinado pelas contribuições de Hume, buscou resolver o problema da indução. Parte da proposta kantiana consiste na ideia de que a percepção seria, na verdade, uma construção realizada perante os estímulos sensoriais. Tal ideia foi crucial para o desenvolvimento teórico do Cérebro Bayesiano. No seguinte trecho, retirado do livro “Crítica da Razão Pura”, Segunda Parte (Lógica Transcendental), do Livro II, Capítulo II, Seção 3 temos que:

[...] Mas como a experiência é uma cognição de objetos por meio de percepções, segue-se que a relação do múltiplo na existência deve ser nela representada não como surge justaposta no tempo, mas como existe objetivamente no tempo; contudo, como o próprio tempo não pode ser percebido, a determinação da existência dos objetos no tempo só pode ocorrer por meio de sua combinação no tempo em geral, e assim, apenas por meio de conceitos que conectam de maneira *a priori*. Ora, dado que estes sempre carregam necessidade consigo, **a experiência é possível apenas mediante uma representação da conexão necessária das percepções** (negrito próprio).⁴

Nota-se, principalmente no trecho destacado, que Kant realçava o papel da experiência, só que esta estaria vinculada a - e seria dependente de - uma anterioridade do arcabouço receptivo da percepção.

Na fisiologia do século XIX, Herman von Helmholtz imprimiu um caráter experimental às bases filosóficas kantianas (Helmholtz, 2000/1924-5). Helmholtz formalizou a ideia de que percepção seria, na verdade, um processo de inferências subpessoais. Intuitivamente, o fisiologista comparou o trabalho do cérebro ao de um cientista, que busca inferir as causas dos eventos partindo de suas observações. Essas

⁴ Tradução da Primeira Analogia da Experiência de autoria de José Oscar de Almeida Marques disponível no Portal UNICAMP. Acesso em 08 de agosto de 2026. <https://unicamp.br/~jmarques/cursos/2010-hf133/Kant_Primeira_Analogia_da_Experiencia.pdf>

observações seriam balanceadas com as informações que o cérebro possui para inferir com certa segurança as causas mais prováveis daquilo que foi observado (Iennaco, Maia, & Sayeg, 2023). A inferência, nesse contexto, seria a conclusão, a partir de premissas conhecidas, tomada como a mais provável sobre determinado evento, fenômeno ou construto (Brown & Brüne, 2012).

Em obras posteriores, Helmholtz explora essas ideias em teorias físicas como a da termodinâmica e da energia livre, onde busca entender as condições de equilíbrio e estabilidade nas razões estabelecidas em propriedades termodinâmicas, incluídas nesse entendimento a energia livre, a quantidade de calor, a temperatura e a entropia (Souza Filho, 1995). O entendimento que Helmholtz buscou sobre a termodinâmica se deu por analogia com a teoria mecânica do calor pela qual o equilíbrio aparente esconde movimentos intensos, levando-o à busca do princípio de mínima ação (Souza Filho, 1995).

Na psicologia do século XX, o psicólogo e filósofo Kenneth Craik (1943) foi um dos proponentes da visão da mente humana como um mecanismo de modelagem preditiva, ideia central do Cérebro Bayesiano. O autor argumentou que o poder de previsão dos eventos do nosso meio é uma das propriedades mais fundamentais do processo de pensamentos. Isso implica, para Craik, que organismos pensantes possuem uma capacidade adaptativa e construtiva, dado que têm uma espécie de modelo de sua realidade externa e suas próprias ações nela. Isto é, modelos que se assemelham aos processos e objetos que representam (Craik, 1943).

O caráter dinâmico desses modelos, por sua vez, pode ser discutido com relação às contribuições obtidas por meio da experiência e da aprendizagem. Conforme ressaltado por Jones e colegas (2011), a formação de um modelo mental advém tanto da biologia quanto da aprendizagem, uma vez que os comportamentos propiciam conteúdo e técnicas para o conhecimento daquilo que o indivíduo aprende. Isso, por vez, lhe permite modificar a natureza e a qualidade (no sentido de melhoria) do seu modelo mental, exponenciando sua capacidade de raciocínio e garantindo as melhores condições fisiológicas para sua sobrevivência.

Ulrich Neisser, autor do livro *Cognitive Psychology* (1967), desenvolveu a ideia de que a percepção é um processo de construção ativa. Tal ideia despertou interesse e reconhecimento de outras áreas, como a relatada em uma entrevista concedida a

Szokolszky (2013) e que merece aqui ser reproduzida pela noção incipiente de “alucinações” relacionada com o tópico deste trabalho:

O outro impulso do meu livro foi que a percepção era uma construção, o que eu achava uma frase fina e maravilhosa. Tinha um certo arroubo retórico, mas lembro-me de uma série de coisas que me fizeram suspeitar disso. Uma vez recebi uma carta de um psiquiatra dizendo como eu estava certo e que ele estava realmente satisfeito em ver isso teoricamente, que a percepção era uma construção, porque ele tinha visto as mesmas coisas nas alucinações de seus pacientes. Eu pensei, hum, não devo ter me expressado corretamente. Eu não quis dizer que a percepção era como uma alucinação! (Szokolszky, 2013, p. 186, tradução própria)⁵

Neisser, que iniciou sua carreira a partir da teoria do processamento da informação, recebeu fortes influências de James Gibson, um dos proponentes da psicologia ecológica, especificamente naquilo que tange à percepção como informação (Szokolszky, 2013). Isso o levou a afirmar que a quantidade de informação utilizada para a formulação da percepção seria, ao menos parcialmente, composta pela informação produzida pelo movimento (Szokolszky, 2013). Conforme veremos, essas ideias de percepção como construção e informação obtida a partir do movimento foram importantes contribuições para a formulação da teoria do Cérebro Bayesiano e da Inferência Ativa.

Richard Gregory, também psicólogo, retoma, no final do século XX, as ideias de Helmholtz sobre inferências e acrescenta a noção de previsibilidade anteriormente explorada por Craik. Para Gregory (1967), as inferências seriam projetadas no mundo exterior, ainda que mantivessem a realidade como imediata, visto que tais inferências se originam de estímulos sensoriais aferidos no presente momento. Em maiores detalhes, Gregory retoma como base empírica o processo da visão, explorando a noção temporal das inferências realizadas acerca de características ainda não detectadas de objetos. Essa noção temporal compensa o ‘atraso’ da sinalização neural e permite a projeção dos

⁵ O trecho original é: “The other thrust of my book had been that perception was constructive, which I thought was a fine and wonderful phrase. It had a certain rhetorical fling to it, but I remember a number of things that made me suspicious of that. Once I got a letter from a psychiatrist saying how right I was and that he was really pleased to see this theoretically, that perception was constructive because he had seen the same things in the hallucinations of his patients. I thought, hmm, I must not have expressed myself correctly. I didn’t quite mean that perception was like hallucination!”

comportamentos, dentre eles os que tomarão um objeto como o resultado da melhor inferência sobre o que tal objeto parece ser (Gregory, 1997).

As contribuições de Neisser e Gregory, tomadas em conjunto, trouxeram para a psicologia e, posteriormente, para o construto do Cérebro Bayesiano, a noção de que a percepção seria uma composição feita de análise e síntese. Isso significa que primeiro ocorre a análise de características dos objetos e elementos constituintes de um estímulo, depois ocorre a ativação de informações contextuais e conhecimento prévio que irá determinar o que é relevante dentre as características dos objetos analisados para reuni-los (sintetizá-los) em uma representação interna do que o estímulo possa ser. Gregory, em especial, avança a noção de que conhecimento perceptual poderia diferir do conceitual (Gregory, 2005).

Na virada do século XX para o XXI, houve um desenvolvimento tecnológico significativo, equipando a neurociência com novas formas de mensuração e simulação computacional. Assim, modelos computacionais e matemáticos deixaram a abstração e passaram a ser implementados em contextos biológicos a fim de tentar representar o funcionamento do cérebro.

Em 1999, Rao e Ballard publicaram o artigo que muitos consideram ser a origem do construto do Cérebro Bayesiano tal como é atualmente conhecido. Os autores traduziram e implementaram um modelo de codificação preditiva - que existia com certa popularidade à época para a otimização da transmissão de imagens e sons no computador - para as dinâmicas do córtex visual humano (Rao & Ballard, 1999). No mesmo ano, Kenji Doya explorou modelos preditivos no contexto de aprendizagem em diferentes estruturas encefálicas. Especificamente, Doya ressaltou o caráter sistêmico da operação dessas estruturas, esclarecendo que, para além da distinção comumente feita por finalidade, deve-se atentar ao caráter interdependente dessas estruturas para que um comportamento, tal qual a aprendizagem, seja alcançado (Doya, 1999). Isso significa dizer que uma determinada função pode se dar através da combinação de diferentes módulos de aprendizagem em cada uma das variadas estruturas acionadas.

O autor que popularizou o construto do Cérebro Bayesiano nas últimas duas décadas provavelmente foi o neurocientista inglês Karl Friston (2003; 2005; 2009; 2010). Friston e diversos colaboradores desenvolveram estruturas formais - a partir da estatística, física, algoritmos de aprendizado de máquina e neurociência computacional - que

constituem o arcabouço do Cérebro Bayesiano. Após o sucesso progressivo, ele seguiu o desenvolvimento de suas ideias para o que hoje chama de Princípio da Energia Livre⁶ e os modelos de Inferência Ativa⁷.

Partindo do trabalho do Friston, vários campos têm cada vez mais implementado esses construtos e modelos de diferentes formas. Na filosofia, por exemplo, Andy Clark e Jakob Hohwy foram responsáveis pela disseminação de versões “livres de matemática” do Cérebro Bayesiano (Hohwy, 2013; Clark, 2016), com trabalhos basilares para a popularização do tópico em áreas que não estão necessariamente familiarizadas com aprendizado de máquina e com a estatística. Na psiquiatria (computacional), modelos de inferência ativa estão sendo utilizados para simular e prever com maior precisão diagnósticos clínicos (*e.g.*, Hodson, Mehta, & Smith, 2024). Assim, ainda que seja um tópico relativamente novo na comunidade científica, é extremamente frutífero, versátil e aberto a exploração e questionamento de todas as áreas de conhecimento. Veremos agora como os desenvolvimentos do Teorema de Bayes se aplicam ao cérebro.

Inferência Bayesiana

Quando aplicada ao funcionamento do cérebro, a Inferência Bayesiana pode nos auxiliar na compreensão e na elaboração de uma nova descrição de vários aspectos da cognição humana, formalizada através da estatística bayesiana e simulada em modelos computacionais. Uma das vantagens e novidades dessa descrição bayesiana de cognição é a inversão do modelo cognitivo tradicional – que consiste em uma percepção passiva de informações sensoriais que processa primeiro as causas e depois as sensações – para um modelo ativo de cognição. Esse modelo ativo faz com que o cérebro, a cada conjunto de informações sensoriais ativamente captadas, processe primeiro um conjunto de hipóteses, mapeando e integrando várias características relevantes tanto das informações captadas quanto de informações internas para depois tentar ‘explicar’ a causa das informações captadas e assim gerar a experiência consciente (Friston, 2010).

⁶ O Princípio da Energia Livre é uma formulação matemática que descreve as dinâmicas dos organismos contextualizados cuja manutenção da vida seria orientada à minimização da entropia informacional interna aos organismos. Esse princípio também formaliza o ciclo ação-percepção e a distinção entre organismos e seu meio, através de membranas estatísticas (Cobertores de Markov).

⁷ A Inferência Ativa é uma forma de modelar o ciclo ação-percepção a partir das escolhas comportamentais do agente, tanto em meio interno quanto em meio externo a ele. O cerne desse modelo é garantir que a divergência entre as crenças do agente e as evidências que ele capta pelos sensores seja mínima.

O Teorema de Bayes (**Equação 1**) aplicado na percepção lida com crenças estatísticas. Isso significa que essas crenças são constituídas como uma distribuição probabilística de um estado ou atributo do mundo que é desconhecido, podendo ou não ser acessadas conscientemente. Assim, as crenças servirão de base para tentar responder qual é a probabilidade de, por exemplo, Alice ter rapidamente visto um cachorro preto em vez de um saco de lixo preto em um beco enquanto andava pela rua. Suponha que Alice *acredita* ter visto o cachorro preto (probabilidade de 0.6) ao invés do saco de lixo (probabilidade de 0.4). Essa crença é composta de informações que ela já possui acerca do mundo e de uma expectativa de que o que ela percebeu é de fato o que ela achou que percebeu. Nesse contexto, uma crença pode ter alta precisão se a distribuição de probabilidade for concentrada no valor mais provável, dadas as experiências anteriores – isto é, a crença for acompanhada de muita expectativa. Em outras palavras, a precisão corresponde à confiança ou ao grau de certeza associada à crença (Adams, Brown, & Friston, 2014).

Se Alice for uma pessoa que gosta de cachorros, ou se ela sabe que o cachorro preto do Beto está perdido, ela irá agir (seja voltando ao local ou realizando um novo movimento ocular) com base na sua crença de que viu um cachorro para confirmar a visão. Nisso, ela completará um ciclo de inferência bayesiana: ela captou uma informação que ela julgou (em processamento bayesiano) ser um cachorro; porque para ela, de alguma forma, era mais interessante alimentar a crença de ser um cachorro que um saco de lixo. Essa informação de suposto cachorro gerou nela um ímpeto de agir para “perceber melhor” o cachorro (ao, por exemplo, buscar saber se ele é o cachorro de Beto), atualizando, portanto, sua crença com novas evidências. Caso o que ela viu fosse, de fato, um cachorro, ela irá atualizar seus modelos com base no erro de ponderação que fez. Isso significa maximizar a probabilidade sobre ser o objeto que acredita ter visto um cachorro e não um saco de lixo (0.9 cachorro contra 0.1 saco de lixo) de modo que os detalhes dele sejam processados. Caso o que ela viu fosse o saco de lixo, o erro inferencial seria supor que fosse um cachorro. Esse erro será por ela utilizado para atualizar seu modelo (0.9 saco de lixo contra 0.1 cachorro) e planejar outro tipo de ação, voltando à sua caminhada.

É importante ressaltar que o Cérebro Bayesiano está limitado a fazer inferências bayesianas de forma a *aproximar* a nossa percepção da realidade, mas nunca a equipará-la à realidade. O motivo disso se dá na característica notada por Hume da impossibilidade

de haver uma inferência completamente correta (probabilidade de 1.0) (Hume, 1748). A ideia central do Cérebro Bayesiano é lidar com inferências que sejam suficientemente acuradas para a realização de interações bem-sucedidas com o nosso meio (Clark, 2013). Não temos acesso à realidade “pura” ou “verdadeira”, mas apenas àquela que diz respeito à nossa *Umwelt* – isto é, aquela realidade que está dentro de nossos limites morfológicos, fenotípicos e até mesmo culturais - sendo esta, no contexto bayesiano, apenas um compilado de inferências para a melhor causa dos efeitos que percebemos (Iennaco, Maia, & Sayeg, 2023). Inclusive, produzir inferências completamente corretas cessaria a necessidade de coletar novas informações do ambiente, nos desconectando do mundo. Isso poderia acarretar sérias consequências para nossa sobrevivência, seja na evitação de situações e estados que ameaçam a nossa existência fisiológica, quanto no desenvolvimento de transtornos mentais, como a esquizofrenia (Adams, Brown, & Friston, 2014). Uma das formas de entender como é realizada essa computação bayesiana no cérebro é através de modelos de Processamento Preditivo.

Processamento Preditivo

Até agora, analisamos a ideia de que o cérebro estaria realizando diversos processamentos que implicam em cálculos estatísticos a nível subpessoal para que não somente funcione de forma otimizada, mas também possa controlar o corpo que navega o mundo. Vimos também a função dos modelos que geram inferências sobre as causas do mundo e a importância do erro inferencial para que possamos nos manter conectados com esse mundo. Alguns aspectos da cognição no contexto bayesiano foram mais bem desenvolvidos na filosofia e nas ciências cognitivas através das teorias de Processamento Preditivo.

De forma mais geral, o Processamento Preditivo é utilizado para descrever tanto filosófica quanto empiricamente os processos cognitivos de minimização de erro inferencial (ou de predição) em diferentes escalas – como a do córtex visual (Rao & Ballard, 1999) e a da percepção consciente (Hohwy, 2013). Por esse motivo, ele tem sido considerado por muitos autores um promissor campo de pesquisa (Wiese & Metzinger, 2017). Dado o escopo do artigo, vamos focar na descrição geral da percepção e da aprendizagem segundo as teorias de Processamento Preditivo.

Percepção

Conforme já mencionado, a percepção neste contexto sofre uma inversão, deixando de ser passiva e passando a ser ativa. A ideia central é que a todo momento estamos ativamente captando novas informações sensoriais para atualizar nossos modelos e, finalmente, percebermos o mundo. Esse mundo, na verdade, nos é oculto, no sentido que não possuímos acesso direto a ele, mas apenas inferencial. Desse modo, precisamos fazer boas inferências sobre o que está causando os efeitos em nossos sensores, de modo que nos seja possível reagir e interagir com sucesso neste mundo. O fato de já termos modelos de mundo e inferências sobre os efeitos captados nos garante uma gama de ferramentas para as interações, o que as tornam menos custosas e mais coerentes, na medida do possível. Por exemplo, veja a **Figura 1**. Trata-se de uma imagem ruidosa ou ambígua no sentido que nossos modelos e informações prévias não conseguem concluir sobre o que se trata em um primeiro momento. Dessa forma, ficamos sem ferramentas para interagir com o conteúdo desta figura, apenas com inferências medianas que são incapazes de dotar de sentido o que está sendo captado.

Figura 1- Imagem ambígua.



Fonte: arquivo pessoal

Agora, se observarmos a **Figura 2**, veremos o conteúdo da imagem em sua forma original e finalmente teremos condições suficientes para atualizar nossos modelos acerca do que se trata a **Figura 1**, possibilitando-nos interagir com seu conteúdo. O que o Processamento Preditivo nos traz de novidade neste pequeno experimento é que uma vez

que olhamos para a segunda imagem, obtemos informações suficientes sobre o conteúdo. Dessa forma, se olharmos novamente para a **Figura 1**, não seremos capazes de ver a mesma ambiguidade uma vez que teremos informações prévias suficientes para resolver essa ambiguidade automaticamente e desvendar o conteúdo da imagem.

Assim, a percepção preditiva utiliza informações que já possuímos acerca do ambiente para criar expectativas sobre o quão similar essas informações serão em comparação com as informações vindouras do ambiente. Curiosamente, tudo que for redundante aos modelos não será processado, poupando recursos do cérebro para aquilo que é diferente do que ele estava esperando (Parr, Pezzulo & Friston, 2022). Por exemplo, ao criar inferências sobre o que era a **Figura 1**, o leitor pode ter esperado que fosse um monstro ou um cenário campestre. Ao ver a **Figura 2**, notou que suas inferências eram diferentes. Isso significa que as divergências foram processadas e assimiladas pelas várias redes cognitivas. Depois de ver a **Figura 2**, no entanto, o cérebro preditivo não precisou mais gastar recursos para processar e assimilar a **Figura 1**, uma vez que tinha inferências poderosas acerca do que estava ali.

Em termos neurocomputacionais, existem dois fluxos de informação que circulam entre as camadas hierárquicas do cérebro preditivo. O fluxo descendente (*top-down*) leva as informações prévias e inferências das camadas mais profundas do córtex às camadas mais superficiais dedicadas majoritariamente ao processamento sensorial. O fluxo ascendente (*bottom-up*) leva as informações sensoriais que são divergentes das inferências das camadas sensoriais às camadas profundas do córtex. Essas informações ascendentes levam o nome de erro de predição (Hohwy, 2020), ao passo que as descendentes são chamadas tanto de inferências quanto de predições. Essas predições não se referem a coisas futuras, que ainda irão acontecer, mas apenas a uma estimativa das informações que ainda não foram obtidas pelo organismo, não havendo, portanto, uma dependência temporal (Sprevak & Smith, 2023).

Figura 2 - Imagem original. Floki (branco) e Pat Churchland (marrom).



Fonte: arquivo pessoal

Em termos neurofisiológicos, o trabalho de Manjaly e Iglesias (2020) trouxe com clareza um modelo de Processamento Preditivo envolvendo as seis camadas do córtex cerebral. As três camadas corticais dedicadas ao processamento de ordem primária contêm neurônios que calculam os erros de predição em camadas supragranulares. São essas células que sinalizam possíveis erros para os neurônios presentes na quarta camada. Estes repassam as informações para os neurônios nas últimas duas camadas, supra- e infragranulares, responsáveis pelas predições. Esse processo se dá em cada córtex (primário, secundário e superior) de forma hierárquica (de capacidade de processamento mais inferior para o de capacidade de processamento mais superior) e entre os córtices. Dito de outro modo, há um processamento preditivo que se dá de forma inferencial obedecendo a uma hierarquia onde há duas subpopulações neurais funcionalmente distintas: unidades de expectativa, responsáveis por comunicar estados sensoriais esperados de cima (camadas mais profundas) para baixo (camadas mais superficiais) e lateralmente dentro da hierarquia de processamento; e unidades de erro, responsáveis por alimentar sinais de erro de predição para cima e lateralmente (Walsh *et al.*, 2020). Note-se que a arquitetura hierárquica do cérebro permite a circulação bidirecional de informações de modo que os modelos sejam sempre atualizados com as informações vindas do ambiente e vice-versa. Ou seja, aquilo que se prevê sobre o ambiente também pode ser melhorado pelos estímulos que o próprio ambiente provê (Friston, 2003; 2005; Clark, 2013).

Dessa forma, a percepção a partir de um Cérebro Bayesiano ocorre através da atualização dos modelos internos com as informações sincronizadas com o ambiente. Para cada erro de predição que chega às camadas profundas do córtex, ocorre a atualização dos modelos internos, que por conseguinte disponibilizará novas predições para continuar o ciclo. Essa operação incessante promove uma troca eficiente com o nosso ambiente de forma auto-organizada, autoevidente e autogerida (Seth, 2013). Em outras palavras, o objetivo desse processo é dar sentido ao mundo atribuindo probabilidades a hipóteses que melhor explicam os dados que recebemos de nossas aferências sensoriais. E isso acontece através de uma atualização contínua da melhor hipótese para cada cenário que se coloca de momento a momento, por meio de um processamento diferencial, que se traduz em um ajuste fino - uma otimização - entre percepção e ação.

Aprendizagem

Aqui, vemos a importância que o Processamento Preditivo dá aos erros de predição. Para garantir que estejamos sincronizados com o mundo, esses erros não podem ser completamente inibidos pelas nossas inferências. E a única forma disso ocorrer é se houver *novidade* neles. Assim, o erro precisa ser minimizado – isto é, incorporado nos modelos – mas não extinguido – isto é, igualado aos modelos (Vasconcelos, 2023). Tal incorporação de novas informações aos nossos modelos pode ser lida como uma forma basilar de aprendizagem. Além disso, o erro de predição não é qualquer informação sensorial. Ele também passa por um processamento para tornar-se útil aos nossos modelos. Especificamente, ele precisa se diferenciar do ruído (isto é, daquilo que não é relevante para o organismo), passando por algumas “filtragens” e “edições” ao longo de seu caminho ascendente pelo córtex cerebral.

Intuitivamente, existem duas maneiras de o Cérebro Bayesiano manter seus modelos sincronizados com o mundo. Uma forma se dá pela substituição ou atualização interna das inferências, traduzidas na forma de crenças, e a outra forma se dá pela substituição ou atualização das amostras sensoriais captadas (Clark, 2013). E, quanto mais ambíguo for o cenário externo (como ilustrado pela **Figura 1**), mais recursos serão direcionados para a captação de novas informações. Para que a sincronização ocorra da forma mais otimizada possível, o Cérebro Bayesiano possui duas outras ferramentas: a

acurácia para verificar a qualidade das inferências e a ponderação de precisão, para avaliar a confiabilidade da informação vindoura (Friston, 2010; Vasconcelos, 2023).

Para que o Cérebro Bayesiano faça uso de inferências, é necessário que elas estejam minimamente contextualizadas. Assim, as inferências devem possuir um grau de expectativa de novidade que, quanto mais alto, menos acurada a inferência será e vice-versa. Geralmente inferências com alto grau de acurácia são utilizadas para representar a estrutura causal do mundo e do próprio organismo, de modo que não requerem atualizações frequentes e nem alto gasto cognitivo. Inferências com baixa acurácia aumentam o grau de expectativa de novidade, o que leva os sensores a ficarem mais abertos à captura de novas informações – informações mais precisas - para melhorar tais inferências (Piekariski, 2021). Dessa forma, o Cérebro Bayesiano faz uma ponderação de precisão dessas informações, com base nas inferências anteriores. Alguns autores consideram a ponderação de precisão como a atenção endógena (que modula os sensores internos e/ou mentais) e exógena (que modula os sensores externos e/ou motores) (Clark, 2013; Feldman & Friston, 2010). Curiosamente, essas inferências anteriores – cujos erros de predição foram incorporados – se acumulam ao longo da vida, formando padrões acerca das regularidades do mundo que são formalizados em uma distribuição probabilística de erros de predição. Em outras palavras, se os erros forem aprendidos, eles serão utilizados para prever os níveis de ruído na amostragem sensorial de um mesmo contexto, atuando, portanto, como informação prévia (*prior*) que orientará as próximas ponderações de precisão (Hohwy, 2013).

Além da ‘abertura’ dos sensores, um outro passo importante para a captura de melhores informações é a ação. Essa ação pode ser interna ou externa, simples - como uma sacada visual - ou complexa – como um movimento de dança. A ação nesse contexto é descrita como “inferência ativa” e é o nosso elo com o mundo (Parr, Pezzulo & Friston, 2020). Percebemos para agir e agimos para perceber. A inferência é ativa quando orientada a uma possível ação. Isto é, o Cérebro Bayesiano calcula a probabilidade de uma ação fazer o objetivo ser alcançado da melhor forma possível. Por exemplo, Alice está com fome e ela quer comer um sanduíche. Para tanto, ela pode abrir a geladeira e verificar se há um sanduíche lá; ela pode ir à cozinha fazer um; ou ela pode ligar para a lanchonete e encomendar um. Nisso, seu Cérebro Bayesiano irá calcular a probabilidade de alcançar o objetivo da melhor forma possível (levando em conta, por exemplo, tempo

e dinheiro) (Smith, Badcock, & Friston, 2020) e, assim, Alice escolhe como quer fazer para matar sua fome. Note-se que o Cérebro Bayesiano não funciona no nível da consciência de Alice, i.e., Alice não estará ciente de todos os cálculos com distribuição probabilística que seu Cérebro Bayesiano realiza, mas do resultado de tais processamentos.

É válido notar que a otimização das ações e, portanto, das inferências ativas, vem do aprendizado ao longo do tempo. Pense em um bebê aprendendo a andar. Seu cérebro objetiva chegar a algum lugar ou pegar um objeto que está longe e para isso ele precisa criar planos de ação para alcançar tal objetivo. Ainda que seu sistema motor não esteja desenvolvido para ele simplesmente andar até o objeto de interesse, o bebê faz inúmeras tentativas, incluindo gangorrear, ficar em pé, sentado etc. até que, eventualmente, ele consegue resolver suas inferências e realizar a ação de andar. Uma vez realizada, ele vai otimizar essa ação, i.e., realizá-la em diferentes espaços e tempos, até o ponto de parecer óbvio e automático.

Em suma, o Cérebro Bayesiano acopla vários aspectos de nosso funcionamento em um único processo de minimizar as chances de nossos modelos estarem distintos do mundo. Vimos que a percepção é construída majoritariamente com as informações que acumulamos ao longo do tempo e finalizada com as novas informações vindas do ambiente. Vimos que aprendizagem ocorre a todo instante nesse nível, mas também a longo prazo, sendo o resultado de múltiplas tentativas e múltiplos erros de percepção e de percurso. O Cérebro Bayesiano está sujeito a cometer vários erros de julgamento como também a se inclinar a preferências que, do ponto de vista psicológico, são disfuncionais. Por exemplo, um erro comum (porém não disfuncional) de nossa percepção pode ser confundir o saco de lixo preto com um cachorro. Já uma inclinação psicologicamente ruim pode ser uma tendência de negatar as vivências (o que poderia levar à depressão). De qualquer modo, o arcabouço do Cérebro Bayesiano nos traz uma nova forma de compreender o nosso funcionamento e de pensar em soluções para nossos problemas cognitivos e comportamentais.

Cérebro Bayesiano e Aprendizagem: Algumas Perspectivas

Passemos agora a analisar o Cérebro Bayesiano na Aprendizagem de forma específica, isto é, utilizando exemplos claros e dedicados a determinada área da

aprendizagem. Faremos isso por meio de três formas distintas de perspectiva: onde parece haver corroboração, onde há espaço para reflexão; e onde pode haver uma explicação. Nosso objetivo aqui se dá no potencial de auxílio que o Cérebro Bayesiano tem para entender aspectos voltados à educação. Para isso vamos nos valer da aprendizagem que ocorre no domínio da linguagem a fim de especificar e ilustrar perspectivas.

Quando bebês adquirem linguagem falada - para aqueles que têm a capacidade de ouvir - isso se dá de forma pré-estabelecida pelo nosso desenvolvimento filogenético, i.e., está pré-programado para acontecer em nossa espécie (Saxton, 2017). O bebê começa a processar os estímulos sonoros que recebe ainda em útero, mais especificamente no terceiro trimestre de gravidez, com base naquilo que seu aparato auditivo em desenvolvimento lhe permite captar para que forme padrões de entonação (melodia) da língua que sua mãe utiliza (Mampe *et al.*, 2009). Ao nascer, essa padronização com base na sua percepção uterina lhe permitirá chorar no contorno melódico da língua pertencente à sua mãe. Isso significa que um bebê de uma mãe cuja língua é o português brasileiro chorará em uma cadência melódica distinta de outro bebê cuja mãe tem como língua materna o japonês (Ramacciotti *et al.*, 2024). Eis um exemplo que parece corroborar o arcabouço do Cérebro Bayesiano pois demonstra como mapas (sobre a sonoridade da língua da mãe) são formados pelo cérebro do bebê que os utiliza adequadamente para formatar sua produção oral (ainda incipiente na forma de vagidos) logo quando sai do útero.

A partir de então, sua produção oral avançará com marcos claros de aquisição (no desenvolvimento neurotípico) permitindo que sua linguagem oral iniciante - dependente da percepção dos sons, fonemas, variações de gênero, tamanho e composição - seja padronizada por meio do ritmo contido nas ondas sonoras captadas pelas aferências sensoriais (audição, visão, toque) (Ramacciotti & Bailer; Noro, 2023; Ramacciotti *et al.*, 2024). Sabemos atualmente que esse processo se dá a partir do processamento das ondas que chegam ao bebê (estímulos) percebidos de forma descontínua, i.e., há movimentos - de 'pedaços' de som no caso da fala, de ordem sacádica como no caso dos olhos, ou de pequenos conjuntos de vibração no caso do toque - que são aferidos em pequenas 'amostras' (Ramacciotti, Bailer, & Noro 2023). Essas amostras constituem mapas com diferentes resoluções de ordem espacial e temporal que permitirão com que o cérebro do bebê realize inferências. Estas permitem com que o bebê comece a se comunicar com

crecente acurácia ao ‘testar’ suas hipóteses sobre regularidade da conjugação verbal por exemplo (como no caso do erro comum de uma criança com cerca de dois anos ao falar “eu fazi” baseado no seu uso comum de “eu comi”), e perceber - através da interação com seu entorno mediante correção – carinhosa, mas efetiva, de cuidadores - a forma correta. Seus erros de predição lhe informaram sobre a forma mais adequada de se comunicar ao utilizar a conjugação verbal e os estímulos recebidos (como de um cuidador ao repetir “ah, eu também fiz”) lhe provieram insumos para gerar um *feedback* de erros adequado. Nessa constante interação com seu entorno através da linguagem, o bebê passa a formar modelos do que é correto falar e sua aquisição poderá seguir o rumo adequado, i.e., otimizado, de desenvolvimento (Ramacciotti, Bailer, & Noro, 2023). Assim concebido, os estágios de aquisição de linguagem nos fazem refletir como o arcabouço do Cérebro Bayesiano pode nos auxiliar a entender mais adequadamente as aparentes ‘anomalias’ que ocorrem ao longo do desenvolvimento linguístico.

Voltemos agora para um exame de como o arcabouço do Cérebro Bayesiano pode ser útil no entendimento de dificuldades fonológicas que algumas crianças podem apresentar. Dado que a discriminação fonêmica é primordial para a aquisição de linguagem, seja a materna ou as adicionais (Kuhl *et al.*, 2005), faz-se importante entender que o processo de aquisição dos sons que compõem o repertório de uma língua se baseia na percepção (pelos bebês) do padrão rítmico da linguagem oral, i.e., da fala (Goswami, 2022). Caso, por exemplo, um bebê não consiga produzir modelos adequados do padrão rítmico da língua que está adquirindo, seja pela incapacidade de produzir esses sons (dificuldades motoras) ou pela impossibilidade de aferi-los corretamente (dificuldades auditivas), ele será incapaz de produzir inferências para que seu processamento preditivo aconteça. Seja por não ter o *feedback* adequado da parte motora ou por não aferir o som exato, sua percepção restará distorcida. Isso impedirá que haja a necessária otimização de modelos mais adequados (com maior probabilidade de correta predição) para que suas interações produzam substrato suficiente para seu desenvolvimento ótimo. Esse bebê tentará, provavelmente inúmeras vezes, mas seu insucesso - caso permaneça desamparado de instrumentos externos como reconhecimento do entorno, tratamento clínico, intervenções e acomodações educacionais - provavelmente o levará a cristalizar sua dificuldade, que se constituirá em obstáculo efetivo à sua comunicação e desenvolvimento.

Examinar, da forma acima exposta, as dificuldades na produção linguística pelo arcabouço do Cérebro Bayesiano permite também compreender por que estudos têm revelado que as crianças com dificuldades de produção linguística utilizam mais recursos de ordem neural e cognitiva sem o devido sucesso que deveria advir de tal dispêndio. De forma específica, Kuhl e colegas (2020) revelaram que crianças com dislexia do desenvolvimento - um transtorno de origem neurobiológica - apresentam uma conectividade funcional falha entre o córtex auditivo primário e o *planum temporale* somado a uma girificação atípica do mesmo tecido cortical. Esta última característica nos permite entender que o substrato basal de ordem neuroanatômica necessário para o desenvolvimento da funcionalidade exigida para a produção da fala poderá sofrer alterações quando do desenvolvimento da linguagem. Mas, de forma crucial, é o déficit na conectividade funcional entre as áreas elencadas - importantes para a segmentação temporal da fala (segmentação espectral-temporal do fluxo contínuo da fala em sons discretos conforme Giraud e Poeppel (2012) e Lehongre *et al.* (2011) indicado por Kuhl *et al.* (2020)) - que aqui nos importa diretamente. Isso porque a conectividade depende do *feedback* correto processado entre as camadas corticais. E esse processo ocorre com a formação de diferentes mapas mentais ao longo do tempo. Dado o processamento atípico advindo da formação (giros) em excesso, poderá haver falhas na geração desses mapas formados a partir da segmentação temporal da fala. Com a falha, a comunicação entre as camadas corticais mais profundas e as mais superficiais terá um descompasso (Meyer, 2018). Isso a tornará menos efetiva ou aquém do esperado, dando ensejo a um *feedback* de erros - necessário para que modelos corretos de consciência fonológica se assentem - que não ocorrerá como no desenvolvimento linguístico típico. Destarte, a conectividade funcional que dá suporte ao desenvolvimento linguístico adequado não ocorrerá.

Considerações Finais

Neste artigo de revisão houve um objetivo claro: trazer para o campo da aprendizagem um arcabouço teórico que ganhou propulsão na última década. Isso foi feito com o intuito de oferecer possibilidades de alargamento bem como de consolidação do entendimento de processos de desenvolvimento que estão na base do aprender. Para alcançar esse objetivo, foram abordadas diferentes formas o Cérebro Bayesiano: definiu-se a nomenclatura básica, fez-se um apanhado histórico, e foram explicados conceitos

fundantes como o do processamento preditivo e da inferência bayesiana para que se pudesse analisar alguns aspectos da aprendizagem por meio de exemplos dentro do desenvolvimento linguístico.

Ainda há muito que ser desvendado, evidenciado e concebido dentro do arcabouço do Cérebro Bayesiano. Acreditamos, no entanto, que a área da aprendizagem, por tratar de aspectos de ordem interdisciplinar situados na interface entre neurociência, psicologia e educação, poderá ser campo fértil para estudos e investigações mais aprofundadas. Os desafios atuais presentes em diferentes ambientes de aprendizagem ensejam esses esforços.

Referências

- Adams, R.A., Brown, H.R., & Friston, K.J. (2014). Bayesian inference, predictive coding and delusions. *Avant: Journal of the Philosophical-Interdisciplinary Vanguard*, 51-88.
- Brown, E. C., & Brüne, M. (2012). The role of prediction in social neuroscience. *Frontiers in Human Neuroscience*, 6, 147.
- Brown, H., Friston, K., & Bestmann, S. (2011). Active inference, attention, and motor preparation. *Frontiers in Psychology*, 2, 218.
- Clark, A. (2013). Whatever next? Predictive brains, situated agents, and the future of cognitive science. *Behavioral and Brain Sciences*, 36(3), 181-204.
- Clark, A. (2016). *Surfing uncertainty: Prediction, action, and the embodied mind*. Oxford University Press.
- Craik, K. J. W. (1943). *The nature of explanation*. Cambridge University Press, Cambridge, UK.
- Dehaene, S. (2022). *É assim que aprendemos: por que o cérebro funciona melhor do que qualquer máquina (ainda...)*. Editora Contexto.
- Doya, K. (1999). What are the computations of the cerebellum, the basal ganglia and the cerebral cortex?. *Neural Networks*, 12(7-8), 961-974.
- Feldman, H.; Friston, K. (2010). Attention, uncertainty, and free-energy. *Frontiers of Human Neuroscience*, 4(215).
- Friston, K. (2003). Learning and inference in the brain. *Neural Networks*, 16(9), 1325-1352.
- Friston, K. (2005). A theory of cortical responses. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences* 360(1456): 815-36.
- Friston, K. (2009). The free-energy principle: A rough guide to the brain? *Trends in Cognitive Sciences* 13(7): 293-301.

- Friston, K. (2010). The free-energy principle: a unified brain theory? *Nature Reviews. Neuroscience* 11(2): 127-138.
- Friston, K., & Kiebel, S. (2009). Predictive coding under the free-energy principle. *Philosophical Transactions of the Royal Society B: Biological sciences*, 364(1521), 1211-1221.
- Friston, K., & Frith, C. (2015) A Duet for one, *Consciousness and Cognition*, (36), 390-405.
- Friston, K., FitzGerald, T., Rigoli, F., Schwartenbeck, P., O’Doherty, J., & Pezzulo, G. (2016). Active inference and learning, *Neuroscience & Biobehavioral Reviews*, 68, 862-879.
- Fuster, J. M., & Bressler, S. L. (2015). Past makes future: role of pFC in prediction. *Journal of Cognitive Neuroscience*, 27(4), 639-654.
- Giraud, A. L., & Poeppel, D. (2012). Cortical oscillations and speech processing: emerging computational principles and operations. *Nature Neuroscience*, 15(4), 511-517.
- Goswami, U. (2022). Language acquisition and speech rhythm patterns: an auditory neuroscience perspective. *Royal Society Open Science*, 9(7), 211855.
- Gregory, R. L. (1967). Comments on the inappropriate constancy scaling theory of the illusions and its implications. *Quarterly Journal of Experimental Psychology*, 19(3), 219-223.
- Gregory, R. L. (1997). Knowledge in perception and illusion. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 352(1358), 1121-1127.
- Gregory R. L. (2005). *The Medawar Lecture 2001 Knowledge for vision: vision for knowledge*. Philosophical Transactions of the Royal Society of London. Series B, Biological sciences, 360(1458), 1231–1251. <https://doi.org/10.1098/rstb.2005.1662>
- Helmholtz. (2000). *Treatise on Physiological Optics 3 Volumes* (Reprinted from the 1924-5 edition). Introduction text and illustrations (J. P. C. Southhall, Ed.). Thoemmes Press. ISBN 1 85506 831 1
- Hipólito, I. et. al. (2021) Markov blankets in the brain. *Neuroscience & Biobehavioral Reviews*, 125, 88-97.
- Hipólito, I., & Kirchhoff, M. (2023) Breaking boundaries: The Bayesian Brain Hypothesis for perception and prediction. *Consciousness and Cognition*, 111(103510).
- Hodson, R., Mehta, M., & Smith, R. (2024). The empirical status of predictive coding and active inference. *Neuroscience and biobehavioral reviews*, 157, 105473.
- Hohwy, J. (2013). *The predictive mind*. Oxford: Oxford University Press.
- Hohwy, J. (2016). The self-evidencing brain. *Noûs*, 50(2), 259-285.
- Hohwy, J. (2020). New directions in predictive processing. *Mind & Language*, 35(2), 209-223.

- Hume, D. (1748). *Philosophical Essays Concerning Human Understanding*. London: A. Millar.
- Iennaco, M. L., Maia, T., & Sayeg, P. (2023). Processamento Preditivo: uma introdução à proposta de unificação da cognição humana. *Principia* 27(3), 425–452.
- Jones, N. A., Ross, H., Lynam, T., Perez, P. & Leitch, A. (2011). Mental models: an interdisciplinary synthesis of theory and methods. *Ecology and Society*, 16 (1), 46
- Kawano, A. e Paiva, J. L. (2023). *Probabilidades: um curso básico de reoferecimento*. São Paulo: Epusp. 1116 k [E-book]. ISBN: 978-65-89190-25-7. DOI: 10.11606/9786589190257. Disponível em <https://www.livrosabertos.abcd.usp.br/portaldelivrosUSP/catalog/download/1012/926/3414?inline=1>
- Kirchhoff, M., Kiverstein, J. (2018) *Extended Consciousness and Predictive Processing: A Third Wave View*. Routledge.
- Koizumi, H. (2008). Developing the brain: A functional imaging approach to learning and educational sciences. In A.M. Battro, K. W. Fischer, & P. J. Léna. *The educated brain*. Cambridge University Press., 166- 180.
- Kuhl, P. K., Conboy, B. T., Padden, D., Nelson, T., & Pruitt, J. (2005). Early speech perception and later language development: Implications for the "critical period". *Language Learning and Development*, 1(3-4), 237-264.
- Kuhl, U., Neef, N. E., Kraft, I., Schaadt, G., Dörr, L., Brauer, J., ... & Skeide, M. A. (2020). The emergence of dyslexia in the developing brain. *Neuroimage*, 211, 116633.
- Lehongre, K., Ramus, F., Villiermet, N., Schwartz, D., & Giraud, A. L. (2011). Altered low-gamma sampling in auditory cortex accounts for the three main facets of dyslexia. *Neuron*, 72(6), 1080-1090.
- Mampe, B., Friederici, A. D., Christophe, A., & Wermke, K. (2009). Newborns' cry melody is shaped by their native language. *Current Biology*, 19(23), 1994-1997.
- Manjaly, Z. M., & Iglesias, S. (2020). A computational theory of mindfulness based cognitive therapy from the "bayesian brain" perspective. *Frontiers in Psychiatry*, 11, 404.
- Meyer, L. (2018). The neural oscillations of speech processing and language comprehension: state of the art and emerging mechanisms. *European Journal of Neuroscience*, 48(7), 2609-2621.
- Parr, T., Pezzulo, G., & Friston, K. (2022). *Active Inference: The Free Energy Principle in Mind, Brain, and Behavior*. 1ªed. The MIT Press.
- Pearl, J. (1988) *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. Morgan Kaufmann.
- Piekarski, M. (2021). Understanding predictive processing. A review. *AVANT. Pismo Awangardy Filozoficzno-Naukowej*, (1), 1-48.
- Ramacciotti, M.C.C., Bailer, C., Hedlund, A., Mattiello, R. (2024). Multilinguismo e Neurociência. In: Relvas, M. Baum, S. (eds.). *O Cérebro que se comunica: diálogo entre a neurociência e as diversas ciências*. ISBN: 978-85-7854-650-2

- Ramacciotti, M. C., Bailer, C., & Noro, G. (2023). Overview of Language Acquisition for an Efficient Inclusion. *Organon*, 38(76), 1-20.
- Rao, R.; Ballard, D. (1999). Predictive coding in the visual cortex: a functional interpretation of some extra-classical receptive-field effects. *Nature Neuroscience*, 2, 79-87.
- Saxton, M. (2017). *Child language: Acquisition and development*. Sage Publications.
- Seth, A. K. (2013). Interoceptive inference, emotion, and the embodied self. *Trends in Cognitive Sciences*, 17(11), 565-573.
- Seth, A. K. (2015). The Cybernetic Bayesian brain: From Interoceptive Inference to Sensorimotor Contingencies. In T. Metzinger & J. M. Windt (Eds.). *Open MIND*: 35(T). Frankfurt am Main: MIND Group.
- Smith, R.; Badcock, P.; Friston, K. (2020). Recent advances in the application of predictive coding and active inference models within clinical neuroscience. *Psychiatry and Clinical Neurosciences*, 75(1), 3-13.
- Souza Filho, O. M. (1995). A física de Helmholtz e suas bases filosóficas. *Revista da Sociedade Brasileira de História da Ciência*, (13), 53-64.
- Sprevak, M., & Smith, R. (2023). An introduction to predictive processing models of perception and decision-making. *Topics in Cognitive Science*.
- Szokolszky, A. (2013). Interview with Ulric Neisser, *Ecological Psychology*, 25:2, 182-199, DOI: [10.1080/10407413.2013.780498](https://doi.org/10.1080/10407413.2013.780498)
- Thornton, C. (2017). Predictive processing simplified: The infotopic machine. *Brain and Cognition*, 112, 13-24.
- Vasconcelos, M. L. I. de. (2023). A inter-relação entre o modelo dos múltiplos esboços e o processamento preditivo para o estudo da consciência (Dissertação de Mestrado). Universidade de São Paulo, São Paulo. Recuperado de <https://www.teses.usp.br/teses/disponiveis/8/8133/tde-17052023-114613/>
- Walsh, K. S., McGovern, D. P., Clark, A., & O'Connell, R. G. (2020). Evaluating the neurophysiological evidence for predictive processing as a model of perception. *Annals of the new York Academy of Sciences*, 1464(1), 242-268.
- Wiese, W. & Metzinger, T. (2017). Vanilla PP for Philosophers: A Primer on Predictive Processing. In: T. Metzinger & W. Wiese (orgs.), *Philosophy and Predictive Processing*, 1. Frankfurt am Main: MIND Group.

Recebido: 11/02/2026

Aceito: 05/04/2026

Publicado: 26/24/2026

NOTA: As autoras foram responsáveis pela concepção do artigo, pela análise e interpretação dos dados, pela redação e revisão crítica do conteúdo do manuscrito e, ainda, pela aprovação da versão final publicada.