

Análise integrada de dados para compreensão dos processos visuais no córtex

Integrated data analysis to understand visual processes in the cortex

*Análisis de datos integrado para comprender los procesos visuales
en la corteza*

Natali Lourenço Nascimento¹

1. Mestranda do Departamento de Psicologia Experimental, Instituto de Psicologia da Universidade de São Paulo. São Paulo-SP, Brasil. Orcid: <https://orcid.org/0000-0002-7905-1171>

Resumo

A compreensão dos mecanismos de processamento visual é essencial para o estudo da percepção visual. Neste artigo, foi discutido as áreas corticais envolvidas no processamento visual, como o córtex visual primário (área V1) e as áreas visual secundária e associativa. Essas áreas desempenham papéis distintos na análise de características visuais, como forma, cor e movimento. Além disso, foi destacado a importância de diferentes abordagens para analisar dados de atividade neural e resposta a estímulos visuais. Conclui-se que a integração de diferentes técnicas de análise, como séries temporais, curva ROC e modelos de rede, pode ampliar o escopo de investigação dos processos de percepção visual. Essas abordagens fornecem insights valiosos sobre a organização e o funcionamento do córtex visual em diferentes níveis de processamento. A aplicação dessas técnicas em estudos de percepção visual pode contribuir para uma compreensão mais profunda dos mecanismos envolvidos na formação da experiência visual.

Unitermos. Percepção visual; córtex visual; séries temporais; curva ROC; modelos de rede

Abstract

Understanding the mechanisms of visual processing is essential for studying visual perception. In this article, the cortical areas involved in visual processing were discussed, such as the primary visual cortex (V1) and the secondary and associative visual areas. These areas play distinct roles in analyzing visual features such as shape, color, and motion. Furthermore, the importance of different approaches to analyze neural activity data and responses to visual stimuli was highlighted. It is concluded that the integration of different analysis techniques, such as time series, ROC curve, and network models, can expand the scope of investigation into visual perception processes. These approaches provide valuable insights into the organization and functioning of the visual cortex at different processing levels. The application of these techniques in studies of visual perception can contribute to a deeper understanding of the mechanisms involved in visual experience formation.

Keywords. Visual perception; visual cortex; time series; ROC curve; network models

Resumen

La comprensión de los mecanismos de procesamiento visual es esencial para el estudio de la percepción visual. En este artículo se discutieron las áreas corticales involucradas en el procesamiento visual, como la corteza visual primaria (área V1) y las áreas visuales secundaria y asociativa. Estas áreas desempeñan roles distintos en el análisis de características visuales, como forma, color y movimiento. Además, se destacó la importancia de diferentes enfoques para analizar datos de actividad neural y respuesta a estímulos visuales. Se concluye que la integración de diferentes técnicas de análisis, como series temporales, curva ROC y modelos de red, puede ampliar el alcance de la investigación de los procesos de percepción visual. Estos enfoques proporcionan información valiosa sobre la organización y el funcionamiento de la corteza visual en diferentes niveles de procesamiento. La aplicación de estas técnicas en

estudios de percepción visual puede contribuir a una comprensión más profunda de los mecanismos involucrados en la formación de la experiencia visual.

Palabras clave. Percepción visual; corteza visual; series temporales; curva ROC; modelos de red

Trabalho realizado no Instituto de Psicologia da Universidade de São Paulo. São Paulo-SP, Brasil.

Conflito de interesse: não

Recebido em: 03/08/2023

Aceito em: 05/12/2023

Endereço para correspondência: Natali Lourenço Nascimento. Email: natali.lourenco.nasc@gmail.com

INTRODUÇÃO

O caminho para o córtex visual refere-se à rota que a informação visual segue desde a captação na retina até a interpretação no córtex¹. Este caminho envolve várias etapas, incluindo a luz sendo capturada pelos fotorreceptores na retina e os sinais elétricos gerados pelos fotorreceptores sendo transmitidos pelo nervo óptico, onde os sinais são encaminhados para os corpos geniculados laterais no tálamo¹. A informação é processada no córtex visual primário (também conhecido como área V1 ou área visual primária) e, durante esse processo, há a transformação da resposta das células para orientações específicas de linhas¹.

Essas células, são chamadas de células simples, pois respondem melhor a linhas ou bordas em uma orientação específica, tendo campos receptivos lineares e sensíveis a características como comprimento, orientação e posição da linha¹. Ao contrário das células simples, as células complexas são menos específicas em relação à posição exata da linha, respondendo a linhas ou bordas em uma orientação específica, mas realizando essa ação em qualquer lugar dentro de seu campo receptivo².

A via do reconhecimento de cores (via parvo celular) é responsável pela percepção de detalhes finos e pela visão de cores³. Os cones na retina são mais envolvidos nesse processo, e diferentes tipos de cones são sensíveis a diferentes comprimentos de onda de luz, contribuindo para a percepção de cores³. Já em relação ao movimento, temos que a via magnocelular (via magno celular) é responsável pelo processamento de movimento e contrastes, sendo os bastonetes na retina, especialmente os sensíveis à luz fraca, e mais envolvidos na detecção de movimento³. Assim, as informações processadas nessas vias especializadas são integradas em áreas superiores do córtex visual.

Essas áreas superiores, são as áreas associativas (V2, V3, V4), área temporal inferior, parietal posterior, multissensoriais e área pré-frontal³. É importante ressaltar que o processamento visual é distribuído por várias áreas corticais e envolve redes complexas de conexões neuronais¹. A percepção final de cor, movimento e outros atributos visuais é o resultado de inúmeras interações entre essas áreas^{1,2}.

Quando pensamos em percepção visual, a compreensão dos mecanismos de processamento do córtex visual primário é indispensável. Os sinais captados contêm informações em relação a características básicas de estímulos visuais como forma, cor e o movimento³. Uma vez transmitidos para a área V1, os sinais visuais são processados e propagados para o córtex visual secundário e o córtex visual associativo³. Tais áreas mais especializadas estão envolvidas em processos

mais analíticos e complexos da visão como a identificação de objetos, reconhecimento de formas e percepção de profundidade². Nesse sentido, temos que existem diferentes maneiras de se representar as áreas visuais do córtex. Podemos analisar sua representação espacial, denominado também como mapa visuotópico (ou retinotópico) ou as propriedades funcionais de seus neurônios².

Existem várias abordagens pelas quais podem ser analisados os dados de atividade neural, conectividade funcional e resposta a estímulos visuais. Dentre elas se destacam as séries temporais, onde pelos métodos ARIMA (*AutoRegressive Integrated Moving Average*) é possível visualizar a média móvel, indicando a influência de dados passados na análise atual e ITS (Séries Temporais Interrompidas) para traçar intervalos regulares no tempo, envolvendo a identificação de interrupções em uma tendência linear^{4,5}. Aplicada a dados biológicos, como no caso de estudos com percepção visual, é possível investigar como a taxa média de disparo influencia outros neurônios em determinadas áreas do córtex e identificar padrões de potenciais de ação e sua amplitude a partir dos dados longitudinais registrados no database⁵. Outra forma de análise, agora voltada para o desempenho do modelo, seria o uso da curva ROC (*Receiver Operating Characteristic*)^{6,7}. Essa curva é comumente utilizada para avaliar a capacidade de um modelo de classificação em diferenciar duas classes⁷. No contexto de estudos de percepção visual, pode-se utilizar a curva ROC para indicar a presença ou ausência de um

estímulo visual associativo com base em respostas comportamentais ou em neuroimagens, como o Eletroencefalograma (EEG)⁶. Além disso, é possível a estruturação de um modelo completo, mapeando suas ligações e correlações, também utilizando análises como GEE (*Generalized Estimating Equations*) e *Network models*^{8,9}. A utilização de tais ferramentas integradas auxilia uma análise holística do córtex visual, não se limitando apenas a um teste estatístico⁷. Em vez de integrar as análises, muitos desenhos de estudos acabam ocultando dados, seja porque não se encaixam no modelo ou por desconhecimento de tais técnicas. Portanto, uma forma mais precisa de avaliação dos dados seria adequar o modelo aos dados e não o contrário¹⁰.

Foi realizado um levantamento de literatura abrangendo o período de 2014 a 2022, com critérios de inclusão, foram obtidos artigos que apresentassem pelo menos duas das técnicas citadas (Curva ROC, séries temporais, GEE e *network analysis*) de modo integrado a análise do córtex visual. Como critério de exclusão, foram desconsiderados artigos que só possuíam uma técnica de análise ou não compunham um escopo experimental. A coleta foi realizada nas bases de dados Scopus e Scielo.

Para aprimorar a precisão e classificação dos dados em relação ao mapeamento do córtex visual, diversos métodos de extração e análise são empregados e aperfeiçoados ao longo dos anos. Neste ensaio, buscou-se analisar como diferentes métodos de correlação e classificação, modelam

os processos de atenção, reconhecimento de cores, objetos entre outros processos de interação do córtex.

Nos estudos com séries temporais existem duas abordagens principais, análises do domínio do tempo e domínio da frequência, embora sejam matematicamente equivalentes, os dados são vistos sob diferentes perspectivas⁵. Enquanto o conceito central é a memória da série no domínio temporal, no domínio da frequência o objetivo é captar ciclos nos dados através da decomposição espectral^{2,11}. No contexto da modelação visual, características típicas calculadas nos dados incluem o número e comprimento de fixações, sacadas e microsacadas, a velocidade do olhar, o tamanho da pupila, a frequência de piscadas ou a distância coberta pelo olhar³.

Consultando parâmetros que determinam o número de termos autorregressivos (p), a ordem de diferenciação (d) e o número de termos de média móvel (q) no modelo^{3,5}. É possível prever e detectar desta forma, estímulos visuais a partir dessas abordagens¹². Nesse sentido, um possível exemplo seria um modelo ARIMA de séries temporais³. Podendo ser aplicado a uma análise de *eye-tracking* onde é possível rastrear a atenção visual a uma determinada área de interesse em detrimento de outros locais de possível fixação visual probabilística⁴.

Ademais, integrando o GEE será fornecido ao método do estudo uma estrutura flexível de modelagem para heterogeneidade e dependência entre as observações, e o fornecimento de dados que modelam a probabilidade de

captação de interesse visual pelos estímulos apresentados¹³. O mecanismo de controle e modulação no contexto do sistema oculomotor e visão ativa, refere-se à capacidade do sistema visual de direcionar e controlar o movimento dos olhos para explorar ativamente o ambiente e obter informações visuais relevantes. Essa funcionalidade é essencial para a percepção visual dinâmica e interativa². O sistema oculomotor é responsável pelos movimentos dos olhos, existem diferentes tipos de movimentos, como sacadas, fixações e seguimentos².

O GEE leva em consideração a correlação entre as observações do mesmo indivíduo¹⁰. Isso pode ser realizado examinando os coeficientes estimados dos preditores e suas significâncias estatísticas⁸. Além disso, é possível verificar a direção das associações e suas magnitudes, examinando de maneira mais eficaz a modulação da visão ativa^{10,13}. As características das sacadas (movimentos rápidos entre pontos de interesse) e das fixações (períodos de olhar estável) podem ser modeladas como variáveis dependentes em um modelo GEE¹³. Isso permite entender como essas características variam ao longo do tempo ou em resposta a diferentes condições experimentais capturando não só a variância entre os indivíduos como também a dependência temporal².

O processo de reconhecimento de um objeto deriva de dois mecanismos: separação do primeiro plano e do plano de fundo de uma sequência de informações visuais². Dessa forma, estudos que envolvem a curva ROC, podem avaliar a

capacidade de classificação em diferir duas classes de estímulos associativos, podendo neste contexto indicar a presença ou ausência de um estímulo. Revelando a taxa de verdadeiros positivos (sensibilidade ou *Recall*) em relação à taxa de falsos positivos (1 - especificidade) para diferentes limiares de classificação⁷. Sendo possível ainda, a utilização de uma interface *Trigger-in* para garantir a precisão temporal dos dados e a sincronização adequada entre os diferentes dispositivos na identificação de estímulos visuais, com a combinação do uso de eye-tracking e do EEG, fazendo com que o sinal de movimento dos olhos acione a marca no eletroencefalograma⁷.

A partir disso, podemos analisar o *Recall* e a especificidade dos sinais gerados⁷. Assim, temos que as rotas para o estudo do processamento visual são integradas com outras áreas do córtex visual, sendo a análise de uma cena segmentada em três níveis: inferior, intermediário e superior². Desse modo, ocorre o agrupamento de diferentes níveis de processamento. Esses níveis incluem os níveis inferiores, como contraste local, cor, movimento e orientação; os níveis intermediários, como propriedades de superfície, distribuição e contorno global; e os níveis superiores, como o reconhecimento do objeto¹¹. Podem ser analisados por diversos limiares de classificação e precisão dos estímulos, sendo por fim mapeados em um modelo de *Network*⁷. A *network analysis* pode integrar dados multimodais, como dados de neuroimagem estrutural e

funcional, para fornecer uma visão mais abrangente da organização cortical relacionada à orientação⁷.

Os elementos do sistema de redes (Networks) decorrem da interação de seus componentes⁹. Os diferentes tipos de interação permitem a coexistência da atuação de diversas redes em paralelo ao "sistema principal". Todas as Networks são compostas por nodos, altamente agregados, entendidos também como compartimentos ou vértices, ligados por linhas que formam ângulos podendo ser direcionados e ponderados (dependentes do modelo de corrente no sistema)⁹. Além disso, é usualmente utilizada para análise e identificação de associação estatística. A análise pode ser feita com dados transversais, medidas repetidas e desenhos longitudinais¹⁴.

Em suma, quando é utilizado o modelo de network o pesquisador deve identificar os componentes do sistema e representá-los em "nodos" ^{9,14}. Em seguida é necessário, a determinação de interrelação entre os nodos para que assim seja possível mapear as "arestas" (*Edges*), ou seja, as linhas que formam os ângulos de representação do sistema¹⁴. Isso requer conhecimento prévio sobre o input e output de cada nodo (dados que formam os nodos)^{9,14}. A representação dos dados da rede pode ser realizada através de matrizes e vetores⁹. Por exemplo, a matriz que contém o fluxo não só representa a presença ou ausência de fluxo (arestas) da fonte do nó "i" para o nó que recebe esse fluxo, representado como nó "j", mas também a quantidade de fluxo transferida por unidade de tempo através das vias da rede ponderada⁹.

Outrossim, outra forma de construção de modelo de Network para análise de processos visuais, seria o uso conjunto de séries temporais³. Realizando a extração de snapshots (capturas instantâneas) de simulações tempodinâmicas de imagens utilizando *eye-tracking* buscando a otimização dos estudos relacionados ao reconhecimento e processamento de imagens no córtex^{3,5,11,15}.

Desse modo, tanto as pesquisas com GEE, otimizando questões como dados perdidos (*missing data*) e intervalos de tempo fixos em medidas repetidas¹⁰, quanto as séries temporais, a análise de curva ROC e os modelos de rede (*Network Models*) podem ampliar o escopo de análise dos processos do sistema visual e promover uma maior compreensão das interações entre estímulos no córtex visual em seus diferentes níveis de segmentação^{3,15}.

CONCLUSÃO

Diante do exposto, podemos concluir que o córtex visual não é apenas uma área passiva que recebe informações visuais, mas um ambiente dinâmico onde a interação entre neurônios e a organização em redes desempenham papéis fundamentais.

REFERÊNCIAS

- 1.Hubel DH, Wiesel TN. Brain mechanisms of vision. Sci Am 1979;241:150-63. <https://doi.org/10.1038/scientificamerican0979-150>
- 2.Kandel E, Schwartz J, Jessell T, Siegelbaum S, Hudspeth AJ. Princípios de neurociências-5. Porto Alegre: AMGH Editora; 2014; pp483-95.
- 3.Vortmann LM, Knychalla J, Annerer-Walcher S, Benedek M, Putze F. Imaging time series of eye tracking data to classify attentional states.

- Front Neurosci 2021;15:664490.
<https://doi.org/10.3389/fnins.2021.664490>
4. Praetorius AK, McIntyre NA, Klassen RM. Reactivity effects in video-based classroom research: An investigation using teacher and student questionnaires as well as teacher eye-tracking. *Zeitschrift für Erziehungswissenschaft* 2017;20:49-74.
<https://doi.org/10.1007/s11618-017-0729-3>
 5. Stadnytska T. Time series research in psychology: Conceptual and methodological issues (Dissertação). Heidelberg: Heidelberg University, The Faculty of Behavioural and Cultural Studies, Institute of Psychology The Faculty of Behavioural and Cultural Studies > Institute of Psychology; 2006. <https://doi.org/10.1027/1614-2241.4.3.113>
 6. Hajian-Tilaki K. Receiver operating characteristic (ROC) curve analysis for medical diagnostic test evaluation. *Caspian J Internal Med* 2013;4:627. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3755824/>
 7. Wu Q, Dey N, Shi F, Crespo RG, Sherratt RS. Emotion classification on eye-tracking and electroencephalograph fused signals employing deep gradient neural networks. *App Soft Comp* 2021;110:107752.
<https://doi.org/10.1016/j.asoc.2021.107752>
 8. Hardin JW, Hilbe JM. Generalized estimating equations. New York: Chapman and Hall/CRC press; 2012; pp721-9.
<https://doi.org/10.1201/b13880>
 9. Scharler UM, Borrett SR. Network construction, evaluation and documentation: A guideline. *Environ Mod Software* 2021;140:105020.
<https://doi.org/10.1016/j.envsoft.2021.105020>
 10. Melo MB, Daldegan-Bueno D, Menezes Oliveira MG, Souza AL. Beyond ANOVA and MANOVA for repeated measures: Advantages of generalized estimated equations and generalized linear mixed models and its use in neuroscience research. *Eur J Neurosci* 2022;56:6089-98.
<https://doi.org/10.1111/ejn.15858>
 11. Behera L, Kar I, Elitzur AC. A recurrent quantum neural network model to describe eye tracking of moving targets. *Found Phys Lett* 2005;18:357-70. <https://doi.org/10.1007/s10702-005-7125-6>
 12. Cho SJ, Brown-Schmidt S, Boeck PD, Shen J. Modeling intensive polytomous time-series eye-tracking data: A dynamic tree-based item response model. *Psychometrika* 2020;85:154-84.
<https://doi.org/10.1007/s11336-020-09694-6>
 13. Godfroid A, Spino LA. Reconceptualizing reactivity of think-alouds and eye tracking: Absence of evidence is not evidence of absence. *Lang Learn* 2015;65:896-928. <https://doi.org/10.1111/lang.12136>
 14. Borsboom D, Deserno MK, Rhemtulla M, Epskamp S, Fried EI, McNally RJ, et al. Network analysis of multivariate data in psychological science. *Nat Rev Meth Prim* 2021;1:58. <https://doi.org/10.1038/s43586-021-00055-w>
 15. Elbattah M, Guérin JL, Carette R, Cilia F, Dequen G. Generative Modeling of Synthetic Eye-tracking Data: NLP-based Approach with Recurrent Neural Networks. *IJCCI* 2020;vol:479-84.
<https://doi.org/10.5220/0010177204790484>