

Representação por grafos do comportamento visual humano na avaliação da dor neonatal

Roberto Magalhães Junior¹, Rafael Orsi², Tatiany Marcondes Heiderich¹,
Marina C. M. Barros³, Ruth Guinsburg³, Carlos Eduardo Thomaz¹

¹Centro Universitário FEI, São Paulo, Brasil

²Centro Estadual de Educação Tecnológica Paula Souza, São Paulo, Brasil

³Universidade Federal de São Paulo, São Paulo, Brasil

jr.rgmag@gmail.com, rafael.orsi@outlook.com, tatyheiderich@gmail.com,
marinamoraesbarros@uol.com.br, ruth.guinsburg@gmail.com, cet@fei.edu.br

Abstract. *This study analyzes the structural dynamics of visual behavior through graph modeling, representing Areas of Interest as nodes and the transitions between them as edges. Data from 102 participants (44 physicians, 29 laypeople, and 29 parents) were collected using eye tracking during the assessment of neonatal faces for pain evaluation. Four aggregation rules were compared using network metrics. Physicians exhibited more focused strategies, with sparser and more organized graphs, prioritizing the nasolabial fold, whereas laypeople and parents showed more dispersed patterns. These results highlight the potential of graph-based approaches to reveal cognitive differences in visual assessment of neonatal pain.*

Resumo. *Este estudo analisa a dinâmica do comportamento visual por meio de modelagem em grafos, representando Áreas de Interesse como nós e as transições entre elas como arestas. Dados de 102 participantes (44 médicos, 29 leigos e 29 pais) foram coletados usando rastreamento ocular durante a avaliação de faces neonatais para a inferência de dor. Quatro regras de agregação foram comparadas utilizando métricas de rede. Médicos exibiram estratégias mais focadas, com grafos mais esparsos e organizados, priorizando o sulco nasolabial, ao passo que pais e leigos apresentaram padrões mais dispersos. Esses resultados evidenciam o potencial da abordagem em grafos para revelar diferenças cognitivas na avaliação visual da dor neonatal.*

1. Introdução

A avaliação da dor neonatal representa um grande desafio clínico, visto que o neonato não possui a capacidade de verbalização. O diagnóstico baseia-se em escalas subjetivas que interpretam sinais fisiológicos e comportamentais objetivos, frequentemente variando conforme a experiência do observador [Balda et al. 2000]. Diante dessa subjetividade, o uso de tecnologias de rastreamento ocular constitui um método eficaz para fornecer medidas objetivas sobre como a informação visual é capturada e processada durante o julgamento clínico em cuidados neonatais.

As abordagens convencionais em rastreamento ocular utilizam métricas de primeira ordem, como histogramas de duração de fixação [Mahanama et al. 2022]. Es-

ses métodos, contudo, ignoram a variabilidade das transições e a organização relacional do olhar. Nesse contexto, a modelagem por grafos permite visualizar o trajeto do olhar, revelando a estratégia do observador: se ele pula de um ponto a outro sem ordem (busca errática) ou se segue uma sequência lógica para fechar um diagnóstico (busca guiada)[Xia et al. 2023].

O objetivo deste artigo é demonstrar como a aplicação de regras de agregação e métricas de rede pode ser promissora para a compreensão dos mecanismos visuais e cognitivos envolvidos na avaliação da dor em recém-nascidos.

2. Trabalhos Relacionados

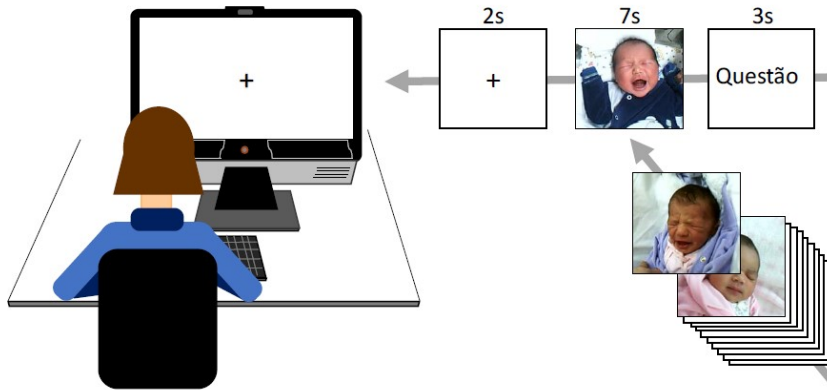
A detecção de estados internos como a divagação mental é desafiadora por sua natureza subjetiva. Para lidar com esse desafio, pesquisadores propuseram o *ETGraph*, que representa fixações oculares como grafos, permitindo identificar padrões de leitura e comparar participantes de forma visual e integrada [Gu et al. 2017]. Yazdan-Shahmorad e seus colegas aplicaram centralidade de grau para analisar o comportamento visual de crianças, mostrando que atenção e tempo de fixação aumentam com a idade, além de evidenciar efeitos transitórios de elementos salientes [Yazdan-Shahmorad et al. 2020]. Outros resultados mostram que métricas de grafos explicam melhor o desempenho em navegação espacial do que variáveis tradicionais [Walter et al. 2023]. Recentemente, foi proposto um método não supervisionado para modelagem da dinâmica pupilar baseado em grafos espaço-temporais dinâmicos e agrupamento guiado por modularidade, capaz de modelar a dinâmica pupilar a partir de eventos neuromórficos (registrados por sensores que capturam apenas mudanças de luz ao longo do tempo, em vez de imagens completas) alcançando desempenho comparável a abordagens supervisionadas, sem depender de rótulos ou imagens RGB [Bandara et al. 2024]. Apesar dos avanços, ainda faltam modelos teóricos consolidados para interpretar métricas de grafos de forma padronizada em processos cognitivos complexos.

3. Materiais e Métodos

Para investigar a dinâmica estrutural do comportamento visual por meio de grafos, utilizaram-se as imagens de faces neonatais do trabalho de [Heiderich et al. 2015], que registrou os movimentos oculares durante a avaliação de dor. Participaram 102 indivíduos: médicos (4 pediatras e 40 neonatologistas, $33,48 \pm 7,01$ anos) com experiência clínica em avaliação da dor neonatal utilizando a escala N-PASS [Hummel et al. 2008], 29 pais ($30,48 \pm 6,95$ anos) de recém-nascidos internados em Unidade de Terapia Intensiva Neonatal e 29 leigos ($39,82 \pm 10,39$ anos), não pais e sem treinamento ou experiência nessa área; todos sem avaliar seus próprios filhos. O rastreamento ocular dos participantes foi realizado com o equipamento Tobii TX300 (300 Hz), em ambiente com iluminação controlada. A Figura 1 apresenta o procedimento experimental no qual os participantes avaliaram as faces, atribuindo notas em uma escala numérica de 0 (ausência de dor) a 10 (dor extrema).

O banco de imagens faciais foi utilizado mediante consentimento dos responsáveis, com aprovação do Comitê de Ética (1299/09 e 3.116.146). A coleta ocorreu em um hospital público de nível terciário. Foram selecionadas 20 imagens (ou estímulos), representando 10 recém-nascidos, cada par composto por uma condição de repouso e outra após procedimento doloroso clinicamente necessário [Heiderich et al. 2015].

Figura 1. Procedimento experimental [Orsi et al. 2023].



O fluxo experimental, ilustrado na Figura 1, foi desenhado para garantir a precisão dos dados oculares. Cada ciclo iniciava-se com a calibração do rastreador ocular e instruções padronizadas, seguidos por dois ensaios de familiarização, que não foram analisados. Para padronizar o posicionamento inicial do olhar, uma cruz foi exibida no centro da tela por 2s. Em seguida, a face neonatal era exibida por 7s em ordem aleatória, evitando efeitos de memorização. Por fim, abria-se uma janela de 3s para a resposta verbal, de modo que o esforço motor da fala não interferisse na captura dos movimentos oculares durante a visualização.

3.1. Modelagem do fluxo visual em grafos

Cada grafo produzido representa a dinâmica das fixações oculares, em que as áreas de interesse (AOIs) são os nós e as transições do olhar entre elas formam arestas direcionadas. As AOIs foram definidas por duas abordagens complementares: (i) semântica, baseada em regiões faciais clinicamente relevantes, e (ii) em grade, por meio de uma segmentação espacial uniforme.

O processo de captura precede a modelagem: o rastreador identifica a posição da pupila em cada quadro do vídeo. Por exemplo, se um participante fixa o olhar no "Nariz" ou numa coordenada espacial dessa área de interesse e depois move para a "Boca", outra área de interesse, essa sequência de quadros gera um vetor de dados que é convertido em uma aresta direcionada [de Magalhães Júnior 2026]. Desse modo, o fluxo visual de todos os participantes da pesquisa foi modelado por diferentes regras de agregação [Endriss and Grandi 2018]. Seja $\mathcal{A} = 1, \dots, a$ o conjunto de indivíduos, em que cada $i \in \mathcal{A}$ define um grafo com arestas $E_i \subseteq V \times V$, sendo V o conjunto de vértices. As funções F formalizam as regras de agregação aplicadas a esses grafos:

1. **Regra da União (RU)** $F_U: E \mapsto E_1 \cup E_2 \cup \dots \cup E_a$, uma aresta entre dois vértices estará presente no grafo coletivo se pelo menos um dos agentes incluir essa aresta em seu grafo;
2. **Regra da Maioria (RM)** $F_{maj}: E \mapsto \{e \in V \times V : |A_e^E| > \frac{a}{2}\}$, uma aresta entre dois vértices estará presente no grafo coletivo somente se mais da metade dos agentes incluírem essa aresta em seus grafos;
3. **Regra da Intersecção (RI)** $F_\cap: E \mapsto E_1 \cap \dots \cap E_a$, considera apenas as arestas que aparecem em todos os grafos individuais fornecidos pelos agentes, baseando-se no consenso absoluto entre eles;

4. **Regra de aprovação do sucessor (RS)** $F_\nu : E \mapsto \{(x, y) \in V \times V \mid y \in \nu(E_1(x), \dots, E_a(x))\}$, que considera uma função $\nu : (2^V)^a \rightarrow 2^V$ que associa quaisquer conjuntos de vértices a um único conjunto de vértices. Em outras palavras, para cada nó, a regra analisa quais destinos foram os mais "votados" pelos participantes, selecionando apenas a trajetória sucessora dominante.

As regras de agregação foram adotadas como aproximações complementares entre a variabilidade individual e a coerência coletiva, buscando modelar o consenso atencional em vez de apenas médias estruturais.

Nessa abordagem, os grafos continuam até 13 regiões associadas à avaliação da dor [Tamanaka et al. 2023]; fixações consecutivas foram fundidas e áreas periféricas excluídas para reduzir redundâncias. Já na segmentação em grade, o tamanho das células envolve um compromisso entre precisão espacial e robustez do sinal: células pequenas aumentam falhas de detecção, enquanto maiores reduzem a especificidade [Vehlen et al. 2022]. Dessa forma, a grade foi definida empiricamente a partir da média das áreas semânticas, gerando uma divisão uniforme do estímulo em uma grade de 18x9 (A1-R9), totalizando 162 células. Como as células representam apenas posições espaciais, sem correspondência semântica, as análises foram realizadas por estímulo. Nessa abordagem, não houve fusão ou exclusão de regiões, preservando a neutralidade espacial e permitindo avaliar a conectividade do olhar de forma puramente geométrica.

3.2. Métricas e Protocolo de análise

As métricas utilizadas para caracterizar o comportamento visual a partir dos dados de rastreamento ocular são apresentadas com suas definições conceituais, estabelecendo a base teórica para as análises subsequentes:

1. **Grau de saída** — número (ou soma ponderada) de transições que partem de um nó, ajudando a identificar quais regiões da face *disparam* a busca por novas informações em outras partes do rosto;
2. **Densidade** — proporção de conexões existentes em relação ao total possível, indicando o nível global de conectividade [Vasudev 2006]. Ela revela se o observador explorou a face de forma dispersa e exaustiva (alta densidade) ou se focou em poucas regiões específicas (baixa densidade);
3. **Similaridade de Jaccard** — medida de sobreposição estrutural entre grafos, que quantifica a semelhança entre as trajetórias de varredura de diferentes observadores ou condições [Newman 2010];
4. **Centralidade de intermediação** — importância do nó como intermediário nos caminhos da rede [Vasudev 2006]. Identifica quais áreas da face funcionam como *âncoras* visuais, permitindo que o observador conecte diferentes sinais expressivos para chegar a um diagnóstico;
5. **Coefficiente de agrupamento** — grau de coesão local entre os vizinhos de um nó. Revela a tendência do observador de realizar um processamento local intenso, conectando repetidamente regiões próximas antes de saltar para áreas mais distantes [Saramäki et al. 2007];
6. **Comunidades** — grupos de nós mais conectados entre si do que com o restante da rede. Reflete a segmentação do espaço observado em unidades funcionais de processamento [Fortunato and Castellano 2012];

7. **Resposta pupilar relativa** — obtida a partir da média dos sinais das pupilas. O sinal é normalizado pela linha de base inicial de cada estímulo (o primeiro valor medido no período de 7s de exposição da face), e calcula-se a média dos desvios absolutos em relação a essa referência ao longo do tempo. Esse valor único representa a variação média da dilatação pupilar, indicando a intensidade da resposta cognitiva [de Magalhães Júnior et al. 2025].

O fluxo visual foi modelado por grafos individuais construídos separadamente para cada participante e tarefa (20 grafos por indivíduo), capturando padrões de exploração específicos ao estímulo. Inicialmente, realizou-se a agregação global dos grafos, sem distinção entre grupos, considerando AOIs semânticas e quatro regras (União, Maioria, Intersecção e Sucessor) para avaliar diferentes critérios de inclusão de transições. Essa análise preliminar foi caracterizada por métricas estruturais e de similaridade — grau de saída, densidade e similaridade de Jaccard —, permitindo selecionar uma regra para as etapas subsequentes.

Na sequência, a agregação foi aplicada em dois níveis — intrapessoal (combinação de tarefas) e interpessoal (integração de participantes) — e a regra escolhida foi utilizada para gerar grafos coletivos tanto no modelo de AOI semântico quanto em grade. Nessas análises, foram consideradas versões ponderadas por frequência de transições e resposta pupilar relativa, avaliadas por centralidade de intermediação, coeficiente de agrupamento e detecção de comunidades ao longo de todo o intervalo temporal (0–7 s), fornecendo uma caracterização integrada da organização estrutural do fluxo visual coletivo.

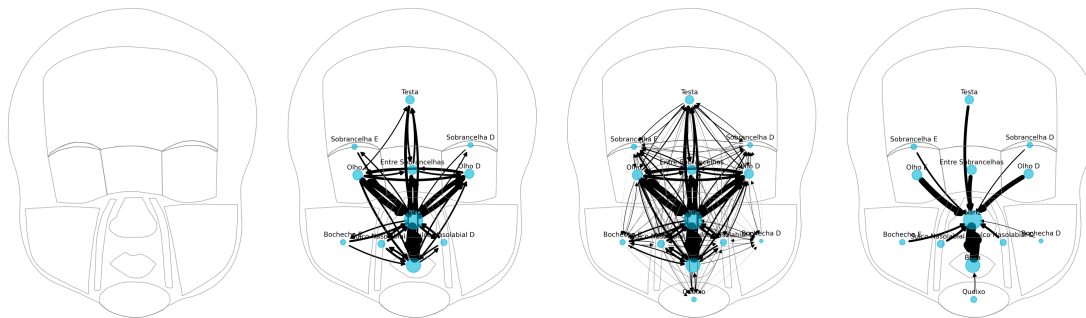
4. Resultados

Inicialmente, comparam-se as estruturas dos grafos sob as diferentes regras de agregação; em seguida, são avaliadas métricas de redes, caracterizando os padrões de exploração visual de cada grupo.

4.1. Comparação das regras de agregação

A Figura 2 ilustra como diferentes estratégias de agregação impactam a estrutura e densidade da rede de atenção visual, considerando todos os indivíduos e estímulos analisados.

Figura 2. Comparativo das regras de agregação (RI, RM, RU e RS).




A regra RI não produziu arestas, indicando ausência de consenso mínimo entre os grafos individuais. A RM apresentou conexões intermediárias, com transições concen-

tradas nas regiões centrais. A RU gerou a rede mais densa, reunindo todas as transições observadas, o que amplia a cobertura, mas reduz a seletividade. Por sua vez, a RS resultou em um grafo mais esparsa e hierarquizado, destacando trajetórias mais diretas e consistentes, com maior clareza dos caminhos dominantes.

A Figura 3 apresenta, da esquerda para a direita, a distribuição do grau de saída, a similaridade de Jaccard e a relação entre densidade e similaridade, permitindo comparar as propriedades estruturais e a convergência entre os métodos. A RI manteve grau e densidade nulos; a RU produziu redes mais densas e conectadas; a RM exibiu maior variabilidade estrutural; e a RS fixou grau de saída igual a 1 por nó, resultando em trajetórias mais seletivas e consistentes.

Figura 3. Métricas de agregação.



Na análise de similaridade, RU e RS exibiram distribuições mais concentradas, indicando maior consistência estrutural, ao passo que RM mostrou maior dispersão. Observou-se ainda que maior densidade não implica necessariamente maior similaridade, especialmente para RM. Valores elevados de Jaccard na RI decorrem de comparações entre grafos vazios, nas quais o índice assume valor unitário por definição.

Em síntese, a RU foi adotada nas análises subsequentes por garantir conectividade e maior representatividade global, enquanto RI, RM e RS permanecem úteis para cenários que priorizem, respectivamente, rigor estrutural, equilíbrio entre inclusão e restrição ou ênfase em trajetórias dominantes do olhar.

4.2. Comparação dos grafos coletivos semânticos

Considerando a modelagem dos grafos semânticos ponderados pela frequência de transições e resposta pupilar relativa, em termos de densidade, os médicos apresentaram valores significativamente menores do que pais e leigos ($p < 0.001$), indicando trajetórias visuais mais seletivas, com menor número de conexões entre AOIs (Figura 4). Pais e leigos não diferiram entre si ($p = 0,79$), exibindo padrões mais dispersos e maior variabilidade individual.

O coeficiente de agrupamento não apresentou diferenças significativas entre os grupos ($p > 0.05$), sugerindo que a organização local das conexões entre AOIs permaneceu semelhante entre Médicos, Leigos e Pais (Figura 5).

De forma semelhante, a centralidade de intermediação não diferiu significativamente entre os grupos para a maioria das regiões ($p > 0.05$). Observou-se apenas um efeito significativo no Sulco Nasolabial Direito ($p = 0.0055$), indicando maior

Figura 4. Distribuição da densidade dos grafos semânticos.

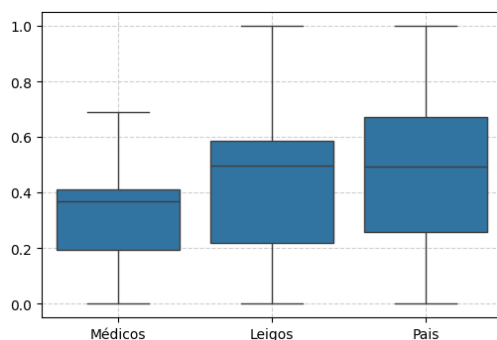




Figura 5. Distribuição do coeficiente de agrupamento dos grafos semânticos.



concentração de transições visuais nessa área entre médicos, possivelmente refletindo atenção direcionada a pistas faciais mais informativas para a avaliação da dor (Figura 6).

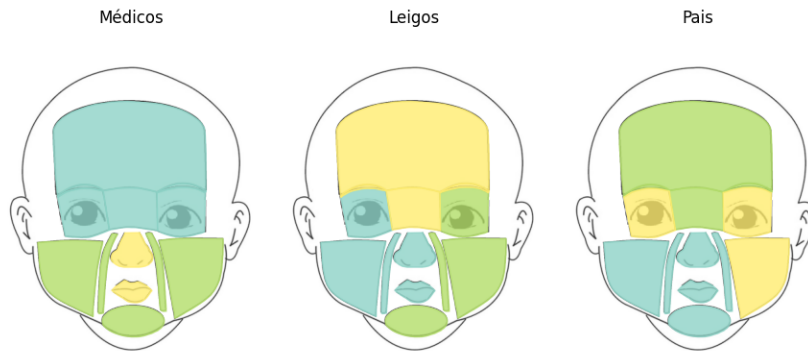
Figura 6. Distribuição da centralidade de intermediação dos grafos semânticos.



Para investigar a tendência de formação de comunidades, aplicou-se o algoritmo de modularidade *Greedy* [Newman 2010] às redes coletivas. Os valores de modularidade foram próximos a zero, indicando conectividade amplamente distribuída entre as regiões. Ainda assim, padrões distintos emergiram: médicos apresentaram organização semanticamente mais coerente, com comunidades centradas nas regiões do nariz e boca e

subdivisões periféricas, enquanto leigos e pais exibiram comunidades mais difusas, sem estrutura clara (Figura 7).


Figura 7. Comunidades dos grafos semânticos.



4.3. Comparação dos grafos coletivos em grade

A Figura 8 apresenta a distribuição da densidade dos grafos para cada estímulo visual (01–20). Observa-se variação consistente entre os grupos, com diferenças em diversos estímulos.

Figura 8. Distribuição da densidade dos grafos em grade por imagem (01-20).



De modo geral, as diferenças mais frequentes ocorreram entre Leigos e Pais, e entre Médicos e Pais, sugerindo influência da experiência profissional ou do papel parental nos padrões de exploração visual. Em diversas imagens (01, 02, 07, 08, 14–20), o grupo de Pais apresentou menor densidade média, indicando fixações mais concentradas. Em contraste, os Leigos exibiram maior densidade e maior variabilidade intra-grupo, refletindo um padrão mais difuso. As diferenças foram estatisticamente significativas na maioria dos estímulos ($p < 0.05$), exceto nas imagens 05, 11 e 13.

O coeficiente de agrupamento apresentou elevada variabilidade entre estímulos, com ampla dispersão e sobreposição entre grupos, dificultando a identificação de diferenças sistemáticas. Esse comportamento pode ser observado no exemplo da Figura 9.

A centralidade de intermediação evidenciou diferenças mais pronunciadas na importância relativa das regiões. Os Pais apresentaram valores ligeiramente mais altos e consistentes (Figura 10), compatível com uma estratégia de exploração mais holística. Os

Figura 9. Coeficiente de agrupamento dos grafos em grade (imagem 10).






Figura 10. Centralidade de intermediação dos grafos em grade (imagem 10).



Médicos mostraram maior variabilidade, alternando entre padrões distribuídos e centralizados, enquanto os Leigos mantiveram valores intermediários.

A análise de comunidades revelou múltiplos agrupamentos espaciais (4 a 11 por grupo) em praticamente todos os estímulos, refletindo a segmentação do campo visual em sub-redes de atenção. Em média, os grafos dos Médicos apresentaram cerca de $4,8 \pm 0,85$ comunidades (1 *outlier*), enquanto Leigos apresentaram $6 \pm 1,0$ e Pais $6,1 \pm 1,41$, sugerindo que os médicos formam redes mais coesas e integradas, ao passo que os demais grupos exibem maior fragmentação espacial. Um exemplo é apresentado na Figura 11.

Figura 11. Comunidades dos grafos em grade (imagem 10).



5. Discussão

As regras de agregação revelaram propriedades distintas: enquanto a RU privilegia a abrangência ao custo da seletividade, regras restritivas como RI e RM resultaram em estruturas excessivamente esparsas devido à alta variabilidade intraindividual

[Yang and Li 2025], indicando que critérios de unanimidade descartam padrões relevantes. Essas diferenças podem ser interpretadas em termos cognitivos. Enquanto a RU privilegia abrangência do espaço atencional, RI e RM enfatizam convergência entre indivíduos. A RS ocupa uma posição intermediária, destacando trajetórias recorrentes e aproximando-se de uma representação de consenso perceptual. Dessa forma, a escolha da regra expressa um compromisso entre cobertura e seletividade.

O problema é análogo à agregação de julgamentos coletivos [McCain 2021]: decisões individuais coerentes podem gerar estruturas coletivas inconsistentes ou pouco informativas. De modo semelhante, grafos individuais válidos podem originar redes coletivas excessivamente densas ou vazias, evidenciando que a agregação é uma questão epistemológica, e não apenas técnica. No presente contexto, a RU maximizou conectividade, porém diluiu contrastes estatísticos ao incorporar transições raras e aumentar o ruído estrutural. Consequentemente, a ausência de significância em parte das análises pode ser interpretada como efeito da densificação do grafo, e não como ausência de diferenças reais. Isso reforça a necessidade de regras ou filtros que preservem conexões informativas sem comprometer a coerência estrutural.

A comparação entre grafos semânticos e grafos em grade também evidenciou impactos da modelagem espacial. As AOIs semânticas capturam relações funcionalmente interpretáveis, enquanto a segmentação em grade descreve o fluxo visual de forma puramente topográfica. Embora a grade revele padrões espaciais mais difusos, ela aumenta a complexidade estrutural e exige definição cuidadosa da granularidade, pois células muito pequenas geram ruído e células amplas reduzem sensibilidade analítica.

6. Conclusão

Este estudo demonstra que a modelagem por grafos é eficaz para caracterizar padrões coletivos de atenção visual, permitindo relacionar propriedades estruturais a estratégias cognitivas. Mesmo quando métricas globais sugerem homogeneidade, nuances topológicas revelam diferenças consistentes entre médicos, leigos e pais, evidenciando a sensibilidade do método em comparação a medidas tradicionais baseadas apenas em frequência ou duração de fixações.

Os resultados indicam que a experiência clínica funciona como uma economia de esforço visual. Enquanto leigos e pais apresentam grafos densos — indicando uma busca visual errática, tentando olhar para todos os pontos (gerando redes densas), o médico foca em conexões específicas e eficientes (gerando redes esparsas). Esse fenômeno pode indicar que o julgamento especializado não demanda um maior volume de informações, mas sim uma integração eficiente entre pontos críticos, como o sulco nasolabial. Esse achado abre caminho para treinamentos baseados em rastreamento ocular, em que pais e estudantes podem ser ensinados a replicar as trajetórias visuais mais assertivas.

A pesquisa levanta, contudo, uma questão fundamental sobre a existência de um caminho de análise ótimo para a dor neonatal. A identificação de uma "estratégia padrão" — se tal configuração ideal de fato existir — representaria o ápice da objetividade clínica. Como perspectivas futuras, recomenda-se o uso de técnicas de filtragem e esparsificação de redes, como filtros de disparidade [Yassin et al. 2023] e extração da espinha dorsal [Ghalmane et al. 2021], além de abordagens de aprendizado de máquina e redes neurais de grafos para seleção automática de transições relevantes [Zhou et al. 2018].

A integração com métricas temporais, como entropia e persistência das sequências de fixação [Melnyk et al. 2024, Raju et al. 2024], pode ampliar a compreensão da dinâmica atencional. Por fim, sugere-se replicar as análises considerando apenas os dois segundos iniciais do rastreamento ocular [Orsi et al. 2023], intervalo com maior poder discriminativo entre grupos para a tomada de decisão em questão.

Referências

- Balda, R. d. C. X., Guinsburg, R., de Almeida, M. F. B., de Araújo Peres, C., Miyoshi, M. H., and Kopelman, B. I. (2000). The recognition of facial expression of pain in full-term newborns by parents and health professionals. *Archives of pediatrics & adolescent medicine*, 154(10):1009–1016.
- Bandara, N. S., Kandappu, T., Sen, A., Gokarn, I., and Misra, A. (2024). Eyegraph: Modularity-aware spatio temporal graph clustering for continuous event-based eye tracking. In *Neural Information Processing Systems*.
- de Magalhães Júnior, R. G., Orsi, R. N., Heiderich, T. M., de Moraes Barros, M. C., Guinsburg, R., and Thomaz, C. E. (2025). Visual and pupillary behavior in neonatal pain assessment using eye-tracking. *IEEE Latin America Transactions*, 23(10):931–937.
- de Magalhães Júnior, R. G. (2026). *Percepção e cognição humana na avaliação visual da dor neonatal usando rastreamento ocular*. Tese (doutorado em engenharia elétrica), Centro Universitário FEI, São Bernardo do Campo, SP.
- Endriss, U. and Grandi, U. (2018). Graph aggregation. In *Companion Proceedings of the The Web Conference 2018*, pages 447–450.
- Fortunato, S. and Castellano, C. (2012). Community structure in graphs. In *Computational complexity*, pages 490–512. Springer.
- Ghalmane, Z., Cherifi, C., Cherifi, H., and Hassouni, M. E. (2021). Extracting modular-based backbones in weighted networks. *Inf. Sci.*, 576:454–474.
- Gu, Y., Wang, C., Bixler, R., and D’Mello, S. (2017). Etgraph: A graph-based approach for visual analytics of eye-tracking data. *Computers & Graphics*, 62:1–14.
- Heiderich, T. M., Leslie, A. T. F. S., and Guinsburg, R. (2015). Neonatal procedural pain can be assessed by computer software that has good sensitivity and specificity to detect facial movements. *Acta Paediatrica*, 104(2):e63–e69.
- Hummel, P., Puchalski, M., Creech, S., and Weiss, M. (2008). Clinical reliability and validity of the n-pass: neonatal pain, agitation and sedation scale with prolonged pain. *Journal of perinatology*, 28(1):55–60.
- Mahanama, B., Jayawardana, Y., Rengarajan, S., Jayawardana, G., Chukoskie, L., Snider, J., and Jayarathna, S. (2022). Eye movement and pupil measures: A review. *Frontiers in Computer Science*, 3:733531.
- McCain, K. (2021). Majority rules? (group belief aggregation).
- Melnyk, K., Friedman, L., and Komogortsev, O. V. (2024). What can entropy metrics tell us about the characteristics of ocular fixation trajectories? *Plos one*, 19(1):e0291823.

- Newman, M. E. (2010). *Networks: an introduction*. [sl]: Oxford university press, 2010.
- Orsi, R. N., Carlini, L. P., Heiderich, T. M., da Silva, G. V. T., Soares, J. d. C. A., Balda, R. d. C. X., Barros, M. C. d. M., Guinsburg, R., and Thomaz, C. E. (2023). Visual attention during neonatal pain assessment: A 2-s exposure to a facial expression is sufficient. *Electronics Letters*, 59(6):e12756.
- Raju, M. H., Friedman, L., Lohr, D. J., and Komogortsev, O. V. (2024). Temporal persistence and intercorrelation of embeddings learned by an end-to-end deep learning eye movement-driven biometrics pipeline. *arXiv preprint arXiv:2402.16399*.
- Saramäki, J., Kivelä, M., Onnela, J.-P., Kaski, K., and Kertesz, J. (2007). Generalizations of the clustering coefficient to weighted complex networks. *Physical Review E—Statistical, Nonlinear, and Soft Matter Physics*, 75(2):027105.
- Tamanaka, F. G., Carlini, L. P., Heiderich, T. M., Balda, R. C., Barros, M. C., Guinsburg, R., and Thomaz, C. E. (2023). Neonatal pain assessment: A kendall analysis between clinical and visually perceived facial features. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 11(3):331–340.
- Vasudev, C. (2006). *Graph theory with applications*. New Age International.
- Vehlen, A., Standard, W., and Domes, G. (2022). How to choose the size of facial areas of interest in interactive eye tracking. *PLoS One*, 17(2):e0263594.
- Walter, J. L., Schmidt, V., König, S. U., and König, P. (2023). Navigating virtual worlds: Examining spatial navigation using a graph theoretical analysis of eye tracking data recorded in virtual reality. In *Proceedings of the 2023 Symposium on Eye Tracking Research and Applications*, pages 1–2.
- Xia, Y., Luo, J., Lan, M., Zhou, G., Li, Z., and Liu, S. (2023). Reason more like human: Incorporating meta information into hierarchical reinforcement learning for knowledge graph reasoning. *Applied Intelligence*, 53(11):13293–13308.
- Yang, K.-F. and Li, Y. (2025). Visual attention graph. *ArXiv*, abs/2503.08531.
- Yassin, A., Haidar, A., Cherifi, H., Seba, H., and Togni, O. (2023). An evaluation tool for backbone extraction techniques in weighted complex networks. *Scientific Reports*, 13(1):17000.
- Yazdan-Shahmorad, P., Sammaknejad, N., and Bakouie, F. (2020). Graph-based analysis of visual scanning patterns: A developmental study on green and normal images. *Scientific Reports*, 10(1):7791.
- Zhou, J., Cui, G., Zhang, Z., Yang, C., Liu, Z., and Sun, M. (2018). Graph neural networks: A review of methods and applications. *ArXiv*, abs/1812.08434.