

Tópicos de Neurociencia Computacional



Docentes: Dr. Sergio E. Lew, Dr. Camilo J. Mininni

Duración: 12 clases (36 horas totales)

Forma de evaluación: Examen final

Programa:

1. Modelos en neurociencia
 - 1.1. Definición de teoría/modelo.
 - 1.2. Distintos tipos de modelos. Ejemplos.
 - 1.3. Iteración entre experimentación y teorización. Utilidad de los modelos.
 - 1.4. Dificultades que presenta el cerebro para su entendimiento.
2. Tópicos de neurofisiología
 - 2.1. Potencial de membrana. Potencial de acción. Transmisión sináptica. Tipos de neurotransmisores.
 - 2.2. Distintos modelos de neurona. Nivel de complejidad del modelo vs. capacidad para explicar fenómenos.
 - 2.3. Elementos de neuroanatomía y neurofisiología.
3. Registro y análisis de la actividad neuronal
 - 3.1. Registros intracelulares y extracelulares.
 - 3.2. Spike sorting.
 - 3.3. Análisis básicos: tasa de disparo, correlación, PSTH, Tuning curves, etc.
 - 3.4. Otros análisis: Reducción de dimensionalidad. Análisis de interacción entre neuronas.
 - 3.5. Métodos ópticos.
4. Integrando neuronas en circuitos
 - 4.1. Necesidad de entender el sistema nervioso en términos de redes de neuronas.
 - 4.2. Circuitos competitivos/WTA/inhibición lateral.
 - 4.3. Plasticidad hebbiana.
 - 4.4. Emergencia de clusters en corteza visual primaria. Adaptación.
 - 4.5. Inferencia bayesiana/codificación de causa oculta.
5. Modulación de la dinámica neuronal y la plasticidad
 - 5.1. Dopamina y dinámica neuronal: efectos en potencial de membrana y excitabilidad. Modelo de Brunel y Wang. Modelo de Durstewitz.
 - 5.2. Dopamina y plasticidad: Modulación de curvas de STDP. Codificación del error de predicción. Modelos de aprendizaje por refuerzo.
 - 5.3. Interacción Corteza Prefrontal - Área Tegmental Ventral.
 - 5.4. Conducta y conectividad rígida y plástica.
 - 5.5. Adaptación desde la evolución hasta la plasticidad.
 - 5.6. Límites sobre el aprendizaje. No free lunch theorem.
6. Desafíos en neurociencia de sistemas
 - 6.1. La maldición de la dimensionalidad y la enorme complejidad del cerebro. Ejemplos.
 - 6.2. Límites técnicos en la cantidad de información que podemos recolectar. Tecnología actual y perspectivas a futuro.
 - 6.3. Límites en las teorías y métodos de análisis. El problema de las tareas simples.

7. Interacción entre neurociencia e inteligencia artificial.
 - 7.1. Nociones básicas: Arquitectura de la red. Función de costo. Algoritmo de optimización
 - 7.2. La IA como generadora de modelos en neurociencia.
 - 7.3. La neurociencia como inspiración para la IA.
 - 7.4. Modelos obtenidos usando métodos de optimización.
 - 7.5. Interpretabilidad de los modelos generados.
 - 7.6. Experimentos derivados de predicciones de modelos.
 - 7.7. El espacio de variables latentes: representaciones emergentes
8. Conciencia.
 - 8.1. Reduccionismo, dualismo y panpsiquismo.
 - 8.2. Teoría de la información integrada.
 - 8.3. Qualia.
 - 8.4. Ejemplos en sistemas sencillos y de pocas neuronas.

Bibliografía:

Libros:

- Rolls, E. T. *Brain computations and connectivity*. (Oxford University Press, 2023).
- Dayan, P. & Abbott, L. F. *Theoretical neuroscience: computational and mathematical modeling of neural systems*. (MIT press, 2005).
- Purves, D. *et al. Neurosciences*. (De Boeck Supérieur, 2019).

Publicaciones seleccionadas:

1. Abbott, L. F. *et al.* An International Laboratory for Systems and Computational Neuroscience. *Neuron* **96**, 1213–1218 (2017).
2. Bashivan, P., Kar, K. & DiCarlo, J. J. Neural population control via deep image synthesis. *Science (80-.)*. **364**, (2019).
3. Bock, D. D. *et al.* Network anatomy and in vivo physiology of visual cortical neurons. *Nature* **471**, 177–184 (2011).
4. Bowers, J. Deep Problems with Neural Network Models of Human Vision. *PrePrint* 1–43 (2022).
5. Box, G. E. P. Science and statistics. *J. Am. Stat. Assoc.* **71**, 791–799 (1976).
6. Brunel, N., Sup, E. N. & Wang, X. Effects of Neuromodulation in a Cortical Network Model of Object Working. 63–85 (2001).
7. Brzosko, Z., Schultz, W. & Paulsen, O. Retroactive modulation of spike timing- dependent plasticity by dopamine. 1–13 (2015). doi:10.7554/eLife.09685
8. Durstewitz, D. & Seamans, J. K. The computational role of dopamine D1 receptors in working memory. *Neural Networks* **15**, 561–572 (2002).
9. Edelmann, E. & Lessmann, V. Dopamine modulates spike timing-dependent plasticity and action potential properties in CA1 pyramidal neurons of acute rat hippocampal slices. **3**, 1–16 (2011).
10. Faisal, a A., Selen, L. P. J. & Wolpert, D. M. Noise in the nervous system. *Nat. Rev. Neurosci.* **9**, 292–303 (2008).
11. Fiorillo, C. D., Tobler, P. N. & Schultz, W. Discrete coding of reward probability and uncertainty by dopamine neurons. *Science (80-.)*. **299**, 1898–1902 (2003).
12. Gao, P. & Ganguli, S. On simplicity and complexity in the brave new world of large-scale neuroscience. *Curr. Opin. Neurobiol.* **32**, 148–155 (2015).
13. Gao, P. *et al.* A theory of multineuronal dimensionality, dynamics and measurement. *bioRxiv* 214262 (2017). doi:10.1101/214262

14. Guo, J.-Z. *et al.* Cortex commands the performance of skilled movement. *Elife* **4**, 160 (2015).
15. Hamid, A. A. *et al.* Mesolimbic dopamine signals the value of work. *Nat. Neurosci.* **19**, 117–126 (2015).
16. Hasson, U., Nastase, S. A. & Goldstein, A. Direct Fit to Nature: An Evolutionary Perspective on Biological and Artificial Neural Networks. *Neuron* **105**, 416–434 (2020).
17. Ho, Y. C. & Pepyne, D. L. Simple explanation of the no-free-lunch theorem and its implications. *J. Optim. Theory Appl.* **115**, 549–570 (2002).
18. Hong, H., Yamins, D. L. K., Majaj, N. J. & Dicarlo, J. J. Explicit information for category-orthogonal object properties increases along the ventral stream. *Nat. Neurosci.* **19**, 613–622 (2016).
19. Hopfield, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proc. Natl. Acad. Sci.* **79**, 2554–2558 (1982).
20. Izhikevich, E. M. Simple model of spiking neurons. *IEEE Trans. Neural Networks* **14**, 1569–1572 (2003).
21. Izhikevich, E. M. Solving the distal reward problem through linkage of STDP and dopamine signaling. *Cereb. Cortex* **17**, 2443–2452 (2007).
22. Jonas, E. & Kording, K. P. Could a Neuroscientist Understand a Microprocessor? *PLoS Comput. Biol.* **13**, 1–24 (2017).
23. Jun, J. J. *et al.* Fully integrated silicon probes for high-density recording of neural activity. *Nature* **551**, 232–236 (2017).
24. Kappel, D., Nessler, B. & Maass, W. STDP Installs in Winner-Take-All Circuits an Online Approximation to Hidden Markov Model Learning. *PLoS Comput. Biol.* **10**, (2014).
25. Kording, K. P. Of toasters and molecular ticker tapes. *PLoS Comput. Biol.* **7**, 1–5 (2011).
26. Kording, K., Blohm, G., Schrater, P. & Kay, K. Appreciating diversity of goals in computational neuroscience. 1–8 (2018). doi:10.31219/osf.io/3vy69
27. Kriegeskorte, N. & Douglas, P. K. Cognitive computational neuroscience. *Nat. Neurosci.* **21**, 1148–1160 (2018).
28. Levenstein, D., Alvarez, V. A., Azab, H. & Prinz, A. A. On the role of theory and modeling in neuroscience. 1–24
29. Luo, L. Architectures of neuronal circuits. *Science (80-.)*. **373**, (2021).
30. Maass, W. Noise as a Resource for Computation and Learning in Networks of Spiking Neurons. *Proc. IEEE* **102**, 860–880 (2014).
31. Markram, H. *et al.* Reconstruction and Simulation of Neocortical Microcircuitry. *Cell* **163**, 456–492 (2015).
32. Masquelier, T. Neural variability, or lack thereof. *Front. Comput. Neurosci.* **7**, 1–7 (2013).
33. Mohebi, A. & Berke, J. D. Dopamine release drives motivation, independently from dopamine cell firing. *Neuropsychopharmacology* **45**, 220 (2020).
34. Nessler, B., Pfeiffer, M., Buesing, L. & Maass, W. Bayesian Computation Emerges in Generic Cortical Microcircuits through Spike-Timing-Dependent Plasticity. *PLoS Comput. Biol.* **9**, (2013).
35. Newell, A. You can't play 20 questions with nature and win: Projective comments on the papers of this symposium. *Mach. Intell. Perspect. Comput. Model* 121–146 (2012).
36. Orbán, G., Berkes, P., Fiser, J. & Lengyel, M. Neural Variability and Sampling-Based Probabilistic Representations in the Visual Cortex. *Neuron* **92**, 530–543 (2016).
37. Park, J., Coddington, L. T. & Dudman, J. T. Basal Ganglia Circuits for Action Specification. 485–507 (2020).
38. Ratcliff, R. & McKoon, G. The diffusion decision model: Theory and data for two-choice decision tasks. *Neural Comput.* **20**, 873–922 (2008).
39. Rosenberg, M., Zhang, T., Perona, P. & Meister, M. Mice in a labyrinth: Rapid learning, sudden insight, and efficient exploration. *Elife* **10**, 1–30 (2021).
40. Rueckert, E., Kappel, D., Tanneberg, D., Pecevski, D. & Peters, J. Recurrent Spiking Networks Solve Planning Tasks. *Sci. Rep.* **6**, 1–10 (2016).
41. Schultz, W., Dayan, P. & Montague, P. R. A neural substrate of prediction and reward. *Science (80-.)*. **275**, 1593–1599 (1997).
42. Seamans, J. K. & Yang, C. R. The principal features and mechanisms of dopamine modulation in the prefrontal cortex. *Prog. Neurobiol.* **74**, 1–58 (2004).
43. Shagrir, O. Marr on Computational-Level Theories *. **77**, 1–26 (2010).
44. Steinberg, E. E. *et al.* A causal link between prediction errors, dopamine neurons and learning. *Nat. Neurosci.* **16**, 966–73 (2013).
45. Urai, A. E., Doiron, B., Leifer, A. M. & Churchland, A. K. Large-scale neural recordings call for new insights to link brain and behavior. *Nat. Neurosci.* **25**, 11–19 (2022).

46. Waelti, P., Dickinson, A. & Schultz, W. Dopamine responses comply with basic assumptions of formal learning theory. *Nature* **412**, 43–48 (2001).
47. Wang, J. X. *et al.* Prefrontal cortex as a meta-reinforcement learning system. *Nat. Neurosci.* **21**, 860–868 (2018).
48. Yamins, D. L. K. *et al.* Performance-optimized hierarchical models predict neural responses in higher visual cortex. *Proc. Natl. Acad. Sci. U. S. A.* **111**, 8619–8624 (2014).
49. Yang, G. R. & Wang, X. Artificial Neural Networks for Neuroscientists: A Primer. *Neuron* **107**, 1048–1070 (2020).
50. Zador, A. M. A critique of pure learning and what artificial neural networks can learn from animal brains. *Nat. Commun.* **10**, 3770 (2019).