

Uma Célula É uma Rede Neural

Lendo a biologia como deep learning

Rafael M. Ehlers · 26 de maio de 2026

rafaelmehlers.com.br/essays/a-cell-is-a-neural-network

A edição de 27 de maio da [newsletter Latent Space](#) trouxe uma analogia à qual continuo voltando. Ela começou com a ideia conhecida de que genes são como programas de computador e foi além: o núcleo é o armazenamento, o ribossomo é um compilador JIT, proteínas são processos, vias de sinalização são fluxos de trabalho. É um mapeamento limpo e vai mais longe do que a versão preguiçosa de que “DNA é apenas código”.

Mas, quanto mais pensei nisso, mais me pareceu que a comparação com computadores deixa de fora a parte mais interessante. Células não se parecem tanto com máquinas de von Neumann. Elas são estocásticas. O mesmo “programa” produz resultados completamente diferentes em contextos diferentes. Os dados e o código continuam se misturando. Nada disso parece estranho quando paramos de comparar células com laptops e começamos a compará-las com aquilo que passamos a última década construindo.

Uma célula é uma rede neural. Ou melhor, o corpo inteiro é.

Comece por como uma vacina funciona.

Você injeta um patógeno enfraquecido ou fragmentado. Seu sistema imunológico nunca o viu, então gera células B com uma ampla variedade de formatos de anticorpos combinados aleatoriamente, seleciona aqueles que se ligam ao alvo e mantém uma memória deles. Quando a versão real aparece, o sistema a reconhece e responde rápido.

Estruturalmente, isso é fine-tuning.

Seu repertório imune depois do desenvolvimento geral é o modelo-base. A vacina é o dado de treinamento. A seleção por afinidade de ligação é a descida do gradiente sobre uma função de perda. As células B de memória são os pesos atualizados. O encontro seguinte com o patógeno é inferência em produção.

Os modos de falha também se encaixam com clareza.

Alergias são overfitting. O sistema aprendeu que pólen, amendoim ou pelos de gato representam uma ameaça. Não representam, mas o modelo se ajustou a uma correlação espúria e agora reage com força a entradas inofensivas. Anti-histamínicos são filtros de saída: eles não corrigem o modelo, apenas suprimem a reação errada em tempo de execução.

Doenças autoimunes são um jailbreak. O sistema perdeu a capacidade de distinguir o próprio do não próprio e começa a atacar seus tecidos. A verificação de segurança que diz “não se ative contra isso” se degradou. Lúpus, diabetes tipo 1, artrite reumatoide: são falhas de alinhamento em um classificador aprendido.

Imunodeficiência é um modelo que perdeu o treinamento de segurança. Sem células T funcionais, como no caso conhecido do HIV, o sistema deixa de distinguir patógenos de micróbios inofensivos, e bactérias comuns se tornam letais. É o mesmo padrão de remover o treinamento de recusa de um modelo de linguagem: o discriminador entra em colapso e tudo passa.

Depois que enxergamos o sistema imunológico dessa maneira, o restante da biologia acompanha. O DNA não é exatamente código-fonte, mas os pesos treinados: comprimidos, opacos, redundantes, legíveis apenas porque passamos décadas fazendo o equivalente à interpretabilidade mecanística sobre eles. A expressão gênica mostra quais características são ativadas em determinado momento. Tipos celulares são diferentes fine-tunings do mesmo modelo-base. Uma célula hepática e um neurônio compartilham pesos; apenas mantêm partes diferentes ativas. Câncer é o que acontece quando mutações suficientes se acumulam e a rede começa a otimizar o objetivo errado.

O que chama atenção é a convergência das ferramentas. Design de proteínas (RFDiffusion, AlphaProteo, ESM3) e edição de modelos (direcionamento de ativações, ablação de características, fine-tuning de comportamentos específicos) fazem o mesmo tipo de trabalho: procuram, em um espaço de projeto de alta dimensionalidade, composições de unidades funcionais que produzam determinado comportamento.

Se isso estiver certo, a implicação é maior que a analogia. A biologia foi o modelo de fundação original. Quatro bilhões de anos de pre-training em um ambiente, um vasto vocabulário aprendido de partes combináveis e uma superfície de produção que agora soma trilhões de instâncias. O deep learning finalmente nos deu um substrato neural que conseguimos treinar em menos de uma era geológica.