

REVISTA DAS QUESTÕES

Conexões matriciais: Perceptron enquanto diagrama

Michael Eby
(Tradução de Rafael Moscardi)

Este artigo explora a história e o legado do perceptron. Começo traçando uma genealogia deste objeto técnico através do trabalho de seu idealizador, Frank Rosenblatt, com foco na construção do perceptron Mark I na Universidade de Cornell, em 1962. Delineio o esquema neurofisiológico que inspirou Rosenblatt, particularmente no que diz respeito à importância das analogias entre o cérebro humano e o funcionamento de computadores eletrônicos. Nesse sentido, discuto a controvérsia que emergiu da crítica ao conexionismo – o paradigma de inteligência artificial (IA) representado pelo perceptron – realizada por Marvin Minsky e Seymour Papert em seu livro de 1969, *Perceptrons*. Para Minsky e Papert, o perceptron tinha limitações graves, que apenas poderiam ser superadas por meio da abordagem que eles chamavam de "IA simbólica". A publicação deste livro é frequentemente considerada o principal fator desencadeador do "inverno da IA", uma ausência de pesquisas em IA por uma década e meia. Usando o trabalho de Trevor Pinch e Mikel Olazaran no campo dos estudos de ciência e tecnologia (ECT), analiso a dissonância entre os dois "modos de articulação" da controvérsia gerada pelo livro,

o “modo de história oficial” e o “modo da área de pesquisa”. Brevemente analiso a prevalência do “modo de história oficial” no campo da teoria crítica da tecnologia contemporânea, bem como alguns dos erros nos quais esse modo incorre. Por último, analiso o retorno do conexionismo como paradigma primário de pesquisa em IA ao final dos anos 80, situando o perceptron nesse contexto, enquanto o núcleo dessas abordagens; ou seja, o autômato finito que gerou ou se desenvolveu em formas mais complexas de redes neurais, hoje largamente utilizadas no *deep learning*. Além disso, traço as maneiras pelas quais a arquitetura original do perceptron sofreu diversas mutações e se transformou em modelo, como por exemplo no caso das redes neurais convolucionais.

Conexionismo

O perceptron foi introduzido pelo psicólogo americano Frank Rosenblatt, professor na Universidade de Cornell. A teorização de Rosenblatt sobre o perceptron foi parte de uma ampla pesquisa acerca do funcionamento do cérebro humano. Em seu artigo de 1958 “O Perceptron: Um Modelo Probabilístico para o Armazenamento e Organização de Informação”, Rosenblatt formula três perguntas acerca das capacidades de processamento de informação do cérebro que, esperava-se, seriam iluminadas por sua pesquisa:

- Como é que a informação sobre o mundo físico é sentida ou detectada pelo sistema biológico?
- De que forma as informações são armazenadas ou lembradas?
- Como é que essas informações armazenadas ou memorizadas influenciam processos cognitivo-comportamentais?¹

Com enfoque nas duas últimas questões, Rosenblatt resume a pesquisa neurofisiológica de seu tempo e as duas respostas conflitantes para este problema. A primeira resposta sugeriria que a memória é constituída por uma correlação um-para-um entre estímulos ambientais e informação neurologicamente armazenada. Nessa visão, uma vez que o diagrama de como o cérebro se configura fosse compreendido, por exemplo, seria possível que pesquisadores reconstruíssem com precisão a memória de um organismo através de uma correlação entre os *inputs* sensoriais e traços de memórias retidos enquanto imagens em um certo espaço de armazenamento no cérebro. Tais “teóricos da memória codificada”² respondem à terceira questão afirmando que cognição e comportamento consistem na combinação de estímulos sensoriais com imagens já armazenadas na topologia cerebral.

Contra esses teóricos da memória codificada, Rosenblatt traz uma teoria oposta, que ele vê como congruente com a tradição do empirismo britânico. Para esses neurofisiologistas empiristas, a segunda e a terceira perguntas são mais adequadamente respondidas por um modelo neurofisiológico que eles chamavam de conexionista.

1 Rosenblatt, Frank, “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain.,” *Psychological Review*, 65, no. 6. 1958. pp. 386–408, <https://doi.org/10.1037/h0042519>.

2 *Ibid.*, p. 387.

As implicações da teoria conexionista da cognição são as seguintes: ao invés de pressupor um espaço de armazenamento de informações que preexiste o ambiente, a memória existe apenas através de um processo de criação. Enquanto os teóricos da memória codificada veem o cérebro como órgão que extrai e armazena imagens do mundo, o conexionismo vê o ato de percepção em si como a criação de novos caminhos neurais e o armazenamento da memória como a criação de caminhos neurais fortes. A trajetória repetitiva de neurônios por um certo caminho determina a sua força: estímulos repetitivos constroem consistência conectiva. Por esse motivo, o armazenamento de informações está articulado à maneira como o organismo percebe o ambiente, como as impressões sensoriais criam conexões sinápticas e como a soma dessas conexões constitui a memória de uma certa experiência. A informação, nesse sentido, é armazenada enquanto preferência por ações em particular, e a capacidade de armazenamento do cérebro humano é, assim, uma vasta rede de associações.

Conexões sinápticas, centrais para o modelo neuroanatômico proposto pelo conexionismo, são formadas por meio do disparo de células nervosas chamadas neurônios. Crucialmente, a especulação de que cientistas construiriam uma imitação matemática das redes neurais cerebrais humanas era uma hipótese já levantada por Warren McCulloch e Walter Pitts em 1943.³ Se referindo a elas como “redes nervosas”, McCulloch e Pitts buscavam definir um cálculo lógico que capturasse a passagem de neurônios através de caminhos

3 McCulloch, Warren S. e Pitts, Walter. “A Logical Calculus of the Ideas Immanent in Nervous Activity,” *The Bulletin of Mathematical Biophysics*, 5, no. 4, 1943. pp. 115–33. <https://doi.org/10.1007/BF02478259>.

sinápticos, entendendo o neurônio como a unidade primária que embasa todos os processos cognitivos do cérebro. Caso isso pudesse ser calculado, seria demonstração clara, acreditavam eles, de que as redes neurais do cérebro humano podem ser implementadas digitalmente enquanto uma máquina de Turing generalizada.⁴ De fato, dois aspectos fundamentais de sua matemática teórica são corporificados no perceptron de Rosenblatt. Primeiramente, McCulloch e Pitts conceituavam o disparo de um neurônio enquanto um evento binário sim-não; um neurônio ou era disparado ou não, e não havia variação de grau nesse sentido. Segundo, um neurônio devia receber estímulos até um certo ponto limiar para que disparasse. Esses limiares seriam atingidos quando a soma total de *inputs* sinápticos de um dado neurônio atingisse um nível suficiente de energia. Ambas essas proposições estão contidas no perceptron de Rosenblatt.

Para além de McCulloch e Pitts, existem dois outros precursores do conexionismo de Rosenblatt, um deles teórico e o outro metodológico. O precursor teórico é o cientista da computação John von Neumann. Von Neumann acreditava nitidamente que os processos cognitivos do cérebro humano poderiam ser capturados por uma máquina digital. Em seu “O Computador e o Cérebro”, ele retrata redes neurais biológicas de uma maneira bastante semelhante a McCulloch e Pitts.⁵ Tendo oferecido sua própria descrição do cérebro e seu funcionamento, von Neumann conclui afirmando categoricamente que este é indiscernível do funcionamento de um computador eletrônico.

4 Ibid., 129.

5 Von Neumann, John. *The Computer and the Brain*. New Haven, Connecticut: Yale University Press, 1958. pp., 39–51.

Essa descrição é a descrição do funcionamento de um órgão em uma máquina digital e da maneira como o papel e a função desse órgão digital devem ser caracterizados. Por esse motivo, trata-se de uma justificativa para a afirmativa original de acordo com a qual o sistema nervoso tem um caráter digital *prima facie*.⁶

A última influência crucial informando a abordagem metodológica de Rosenblatt é encontrada no trabalho do ciberneticista britânico W. Ross Ashby. Essa influência é reconhecida em seu livro de 1962, que expande o escopo e as formulações ligadas ao perceptron, e no qual Rosenblatt admite a apropriação da abordagem focada em erros no que tange ao treinamento de sistemas, tal como a ênfase de Ashby em probabilidade.⁷ Apesar de Ashby não ser especificamente afiliado a um modelo neurofisiológico – favorecendo uma abordagem “caixa-preta”, na qual o pesquisador se ocuparia apenas dos *inputs* e dos *outputs* – Rosenblatt admirava a pesquisa de Ashby sobre sistemas homeopáticos, que demonstravam que “um sistema adaptativo deve conter variáveis, procedimentos próprios, e a habilidade de se reorganizar aleatoriamente para se ajustar ao ambiente”.⁸ Sendo assim, apesar da ausência de uma imagem específica do cérebro em Ashby, o fato de que ele visualizava o sistema nervoso como “essencialmente mecânico”⁹ e seu foco em aprendizado adaptativo através de feedback negativo são congruentes com o modelo neurofisiológico que

6 Ibid., p. 44.

7 Rosenblatt, Frank *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Buffalo, New York: Cornell Aeronautical Laboratory, 1961. p. 25.

8 Kline, Ronald R. *The Cybernetics Moment: Or Why We Call Our Age the Information Age*, New Studies in American Intellectual and Cultural History. Baltimore: Johns Hopkins University Press, 2015. p. 52.

9 Ashby, W. Ross. *Design for a Brain: The Origin of Adaptive Behavior*, 1960.

Rosenblatt emprega através de sua linhagem intelectual traçada entre McCulloch, Pitts e von Neumann.

Assim, a linhagem de teorias neurofisiológicas conexionistas – nas quais processos cognitivos podem ser modelados matematicamente e mecanicamente – em conjunto com a abordagem de Ashby e seu enfoque em sistemas adaptativos que aprendem por meio de tentativa e erro – inspiraram a abordagem de Rosenblatt para a IA e sua crença de que ele poderia construir o perceptron através desse aporte teórico. De fato Rosenblatt declara, na introdução de seu *Princípios de Neurodinâmica* que “há um consenso geral de que a capacidade de processar informação em redes biológicas não depende de nenhum poder vitalista específico que não possa ser replicado em dispositivos feitos pelo homem”¹⁰.

Perceptron Mark I

Rosenblatt havia inicialmente pensado o perceptron como uma máquina específica, porém sua primeira implementação concreta foi como um programa de software em um computador produzido em escala-industrial, o IBM704 na Universidade de Cornell, em 1957.¹¹ Só em 1962 Rosenblatt

10 Rosenblatt, *Principles of Neurodynamics*.

11 Boden, Margaret A. *Mind as Machine: A History of Cognitive Science*, Volume 2. Oxford: Oxford University Press; New York: Clarendon Press, 2006. p. 903.

conseguiu angariar os recursos necessários para produzir o perceptron como um dispositivo de hardware customizado. Essa primeira materialização foi chamada de Perceptron Mark I. Rosenblatt e sua equipe da Biblioteca Aeronáutica de Cornell utilizaram o Mark I para classificar imagens.

A equipe de Rosenblatt publicou um manual de operador que descrevia os métodos de construção e treinamento do Perceptron Mark I.¹² O manual estipulava que a máquina seria composta de três tipos de unidades: unidades sensoriais (unidades-S), unidades de associação (unidades-A) e unidades de resposta (unidades-R). Cada uma dessas sub-unidades corresponde a uma camada do perceptron, e essas camadas estão organizadas sequencialmente. Cada sub-unidade recebe energia, na forma de luz ou eletricidade, e quando a energia total de estímulo de uma unidade chega a um limite específico, a sub-unidade transmite a energia recebida para as sub-unidades com as quais ela está conectada, na próxima camada. Cada unidade-S está conectada a múltiplas unidades-A e cada unidade-A está conectada a múltiplas unidades-R.

As unidades-S são fotoresistores – células condutoras que registram luz visível. Há 400 fotoresistores organizados em um quadro 20x20. A camada-S de fotocélulas gera uma imagem de 400 pixels rudimentar do objeto que o perceptron tentará classificar. No manual, as unidades-S são retratadas como retinas, e elas respondem – assim como o modelo neuronal formulado por McCulloch e Pitts – de acordo com a intensidade dos estímulos recebidos numa base de “tudo-ou-nada”. O sinal de output que uma unidade-S transmite para

12 Hay, John C., Lynch, Ben E., e Smith, David R. “Mark I Perceptron Operators’ Manual”. Buffalo, New York: Cornell Aeronautical Laboratory, 1960.

as unidades-A possui uniformemente uma magnitude de 24-volts. A apresentação desses estímulos é automatizada por um projetor de slides de 35mm. O projetor é colocado em uma caixa sem interferência externa de luz para que seja obtido um melhor contraste e para evitar possíveis ruídos. As projeções eram, em sua maioria, letras do alfabeto ou formas geométricas primitivas. Baseado em quais fotocélulas são ativadas, o campo retinal seria, teoricamente, capaz de classificar padrões planos, tais quais a “posição no campo retinal de visão, a forma geométrica, a recorrência e o tamanho”.¹³

As unidades-A seriam análogas aos neurônios cerebrais. Cada unidade-A consiste em um transistor amplificador e um relé. Cada uma das 512 unidades-A está conectada a um máximo de 40 unidades-S. O input recebido por uma unidade-A é a soma dos outputs de todas as unidades-S de 24 volts. O limite para cada unidade-A varia entre 0 e 100 volts.¹⁴ É crucial que as conexões entre a camada-S e a camada-A sejam “pseudo-aleatórias” para “eliminar qualquer viés intencional particular no perceptron”. Essa configuração pseudo-aleatória demonstraria a capacidade de auto-organização do perceptron, partindo de uma rede inicialmente desorganizada. O que também o tornava único em relação a outros trabalhos em computadores digitais de seu tempo, baseados em conexões previamente organizadas.¹⁵ Margaret Boden afirma ainda que o modelo de cabeamento de Rosenblatt foi diretamente inspirado pelos sistemas homeostáticos de Ashby em sua ênfase na teoria da probabilidade em detrimento da lógica booleana

13 Ibid., p. 1.

14 Ibid, p. 48.

15 Bishop, Christopher M. *Pattern Recognition and Machine Learning*, Information Science and Statistics. New York: Springer, 2006. p. 196.

privilegiada por outros estudiosos no campo da cibernética.¹⁶ Presumivelmente, Rosenblatt precisava deste tipo de cabeamento para delimitar a diferença entre o trabalho dos teóricos da memória codificada e o seu modelo neurofisiológico, que dava ênfase apenas a associações conectivas ao invés da alocação mnemônica num dado espaço topológico.

A camada-A, por sua vez, envia sinais elétricos para a camada-R em uma voltagem não-constante – diferentemente da conexão anterior entre camadas, a voltagem transferida pela conexão de uma unidade-A para suas unidades-R varia de acordo com o valor que corresponde ao sucesso de uma unidade-A particular em ativar suas unidades-R. Mais do que uma simples conexão feedforward entre as camadas, cada unidade-A recebe feedback de suas unidades-R. Esse processo faz com que a voltagem de cada conexão seja continuamente variável. Os valores de sucesso, ou seja, os valores que suscitam comportamentos servomecânicos entre a camada-A e a camada-R são mensurados por potenciômetros – resistores rotatórios que registram voltagem –, que são movidos por uma série de motores elétricos DC. Os potenciômetros são capazes de realizar ponderações adaptativas – ou *wipers*¹⁷ – de acordo com o algoritmo de aprendizado do perceptron, assim treinando o sistema. Esse tipo de aprendizado próprio baseado em processos de tentativa-e-erro que se desdobram através de feedbacks negativos apontam, novamente, para a influência dos sistemas homeostáticos de Ashby em Rosenblatt.

Desta forma, a soma dos valores de sucesso da camada-A constitui a memória do perceptron. Essas linhas conectivas

16 Boden, *Mind as Machine*, p. 905.

17 Hay, Lynch, and Smith, "Mark I Perceptron Operators' Manual," p. 35

são, portanto, análogos mecânicos às sinapses cerebrais relacionadas à teoria do conexionismo neurofisiológico, no qual a memória é constituída de caminhos neurais e no qual a recuperação de informações é baseada em associações.

As unidades-R registram um valor de 0 ou 1 dependendo de a voltagem total de seus *inputs* ultrapassar ou não o valor limite de uma dada unidade-R. Cada unidade-R é composta por um interruptor e um relé. O sinal elétrico recebido pelo interruptor deve exceder o limite da unidade-R ou o relé não será fechado. Existem 8 dessas unidades-R, cada uma das quais envolve uma luz de resposta, que quando acesa indica um valor de 1 e, quando apagada, um valor 0. Esse valor de resposta é enviado de volta às unidades-A (a menos que o ciclo seja manualmente interrompido), assim alterando a voltagem da linha conectiva entre a unidade-R e a unidade-A e as medições dos potenciômetros ponderados.

Muitos pesquisadores do campo se mostraram bastante entusiasmados em relação ao Mark I de Rosenblatt, ainda que alguns outros desdenhassem do artefato. O trabalho de Rosenblatt sempre foi visto como um esforço de alto-nível pela comunidade científica, em particular quando veículos da imprensa *mainstream* nos Estados Unidos fizeram questão de publicar as metas do artigo original sobre o perceptron.¹⁸ No livro “Talking Nets: An Oral History of Neural Nets”, publicado em 1999, Jack Cowan, na época um importante pesquisador em neurologia, relembra: “[Rosenblatt] afirmou que poderia diferenciar um triângulo de um círculo através de seu perceptron. Isso estava tudo errado; você não

18 “New Navy Device Learns by Doing: Psychologist Shows Embryo of Computer Designed to Read and Grow Wiser,” *New York Times*, 7 de julho de 1958, p. 25.

conseguiria fazer coisas desse tipo. [...] no geral estava claro que o perceptron não estava fazendo as coisas que Frank afirmava que ele poderia fazer”.¹⁹ James Anderson, um professor de ciência cognitiva na universidade de Brown, se posicionou de maneira muito mais simpática, dizendo: “A conclusão é que os perceptrons de fato tem algumas limitações severas em termos de poder de processamento; no entanto, essas limitações parecem corresponder às forças e fraquezas mostradas por humanos. Talvez redes neurais não sejam dispositivos de engenharia muito bons, mas sejam ótimos modelos para o funcionamento da mente.”²⁰

Ambos os pontos de vista propostos por esses acadêmicos convergem quanto à profunda significância dos argumentos apresentados no livro de 1969 de Marvin Minsky e Seymour Papert, *Perceptrons*, e quanto ao profundo impacto desse livro no discurso sobre IA da época. No livro, Minsky e Papert fazem uma crítica ao conexionismo. Para eles, a melhor abordagem para pesquisas em IA não seria o conexionismo, mas a abordagem deles, de IA simbólica.

19 Anderson, James A. e Rosenfeld, Edward, eds. *Talking Nets: An Oral History of Neural Networks*. Boulder, Colorado: NetLibrary, Inc., 1999. p. 100.

20 *Ibid.*, pp. 154–55.

A função XOR

Perceptrons: An Introduction to Computational Geometry, de Minsky e Papert, lançado em 1969, especulava que o perceptron e, por extensão, toda a abordagem conexionista de IA possuía limitações severas.²¹ Minsky e Rosenblatt eram conhecidos de longa data, tendo estudado juntos desde o ensino médio, e sempre acompanharam o trabalho um do outro desde a adolescência.²² A crítica de Minsky e Papert buscava desacreditar o trabalho de Rosenblatt devido ao que eles percebiam como uma falta de rigor matemático. As três críticas que seu livro construiu contra o perceptron lidam particularmente com o reconhecimento de padrões complexos, a performance da função XOR e as limitações de uma rede de uma camada.

Primeiro, Minsky e Papert argumentam que o perceptron apresentava muitos problemas ao registrar contraste plano e conectividade entre objetos. Esse problema era representado por uma ilustração na capa da edição revisada de 1972 do livro. Nessa capa, havia uma figura geométrica roxa rodopiante em um fundo vermelho. Tanto a figura geométrica quanto o contraste de cor entre a figura e o fundo tornam muito difícil dizer, à primeira vista, se a forma geométrica é de fato contínua ou se ela se quebra em algum ponto. Para decidir se a figura é totalmente conectada, o olho humano deve seguir suas curvas até o fim. A incapacidade de afirmar se a figura está conectada ou não constitui um problema que afeta não apenas os humanos, mas também o perceptron. Minsky e Papert demonstraram que o perceptron de Rosenblatt tinha

21 Minsky, Marvin e Papert, Seymour A. *Perceptrons: An Introduction to Computational Geometry*. Cambridge, Massachusetts: The MIT Press, 1969.

22 Crevier, Daniel. *AI: The Tumultuous History of the Search for Artificial Intelligence*. New York, NY: Basic Books, 1993. p. 102.

dificuldades em registrar a conectividade de objetos, assim como contrastes sutis de luz e cor.

Além disso, o livro argumenta corretamente que um perceptron de uma camada é incapaz de classificar padrões não lineares; suas capacidades classificatórias estão limitadas a padrões que são linearmente separáveis. Em geometria euclidiana, separabilidade linear se refere ao agrupamento de dois conjuntos de dados em regiões A e B. Isso é visualizado de maneira mais simples no caso de um plano bidimensional. Se uma linha ou um limite são capazes de definir perfeitamente um conjunto de dados em A e B, o padrão é considerado linearmente separável. Se uma distribuição de dados não é tão claramente delimitada, o padrão é considerado não-linear. O perceptron de Rosenblatt só reconhecia padrões linearmente separáveis, limitando bastante os tipos de estímulo que ele era capaz de classificar.

Um exemplo significativo dessa limitação a dados linearmente separáveis está na sua inabilidade de executar uma função booleana XOR, também conhecida como a função OR exclusiva. Foi essa inabilidade que teve o maior impacto na comunidade de estudiosos de inteligência artificial.²³ A função XOR é uma operação que retorna um resultado verdadeiro se A ou B, mas retorna falso se o *input* for "ambos" ou "nenhum". Ou seja, ela retorna como verdadeira apenas se os *inputs* forem diferentes entre si. Novamente, visualizado em um plano bidimensional, esse padrão de dados da função XOR é separável apenas quando são utilizadas duas

23 Russell, Stuart J., Norvig, Peter e Davis, Ernest. *Artificial Intelligence: A Modern Approach*, 3rd ed, Prentice Hall Series in Artificial Intelligence. Upper Saddle River: Prentice Hall, 2010. pp. 730–31.

superfícies de decisão. O livro de Minsky e Papert convincentemente demonstrou que um perceptron de uma camada é incapaz de executar a função XOR, uma limitação bastante importante e em torno da qual diversas discussões emergiram.

É importante notar que ambas essas críticas advêm do fato de que o perceptron de Rosenblatt possuía apenas uma camada de neurônios. Uma rede neural de uma camada não consegue computar muito, necessitando de mais camadas para executar operações complexas. No entanto, o livro de Minsky e Papert foi frequentemente interpretado como prova de que, mesmo em perceptrons com múltiplas camadas, o problema da separabilidade linear não seria solucionado. O livro foi interpretado como refutação do campo conexionista em sua totalidade.

Modos de articulação

O livro de Minsky e Papert é frequentemente creditado pelo desencadeamento de um certo “inverno da Inteligência Artificial”, uma ausência de interesse, financiamento e pesquisa em redes neurais, que se estendeu dos anos 70 até a metade dos anos 80.²⁴ Como afirmado acima, ainda que muitos dos pesquisadores do campo concordassem com a crítica relativamente incontroversa de Minsky e Papert de que um perceptron de camada-única não conseguiria realizar uma

24 Russell, Norvig, e Davis, *Artificial Intelligence*, p. 22.

função XOR, o livro foi citado em seu tempo como uma afirmação que até mesmo perceptrons com múltiplas camadas seriam incapazes de superar esse obstáculo. Por essa mesma razão, ao longo dos anos 70, o livro foi visto como tendo descreditado de um modo geral a pesquisa em redes neurais. Essa interpretação – de que o livro demonstrou que mesmo perceptrons de camadas-múltiplas não conseguiriam executar a função XOR – é, como pretendo demonstrar, infrutífera. O livro não demonstrou nada nesse sentido. O papel que a obra teve enquanto um gatilho do dito “inverno da IA” é muito mais complexo do que essa narrativa institucional nos mostra.

Trevor Pinch, em seu ensaio “What Does a Proof Do if it Does not Prove?”, analisa problemas de comunicação nas ciências, focado em especial nas maneiras como diferentes comunidades científicas articulam um “objeto cognitivo em disputa”.²⁵ Esses objetos de disputa tomam a forma de uma contribuição específica – um texto, uma prova, uma interpretação – que é registrada enquanto um evento e “pode ser analisada em mais de uma dimensão”.²⁶ Quando diferentes comunidades científicas, devido a diferentes condições ou preocupações práticas, acabam aderindo a diferentes dimensões de um certo objeto em disputa, a comunicação torna-se cada vez menos possível entre elas. A aderência a uma dimensão específica desses objetos é chamada por Pinch de um “modo de articulação.”

25 Pinch, Trevor J. “What Does a Proof Do If It Does Not Prove?,” in *The Social Production of Scientific Knowledge*. Springer, 1977. pp. 171–215.

26 *Ibid.*, p. 173.

Dois modos de articulação são explicados por Pinch: o modo típico da “área de pesquisa” e o modo da “história oficial”. O modo da área de pesquisa analisa o objeto em disputa como um problema imediato. Nesse sentido, ele permite uma certa flexibilidade interpretativa ao objeto em questão. Para pesquisadores que adotam esse modo, o objeto em disputa está, em algum grau, ainda em aberto. Aspectos particulares são pouco sólidos e hipóteses podem ser adicionadas ou subtraídas do objeto. Para pesquisadores que adotam o modo de “história-oficial”, as condições não estão abertas. A flexibilidade interpretativa é ausente e o objeto em disputa é visto como um objeto fechado. Pinch argumenta que este modo de história oficial é articulado quando o objeto se encontra fora das preocupações imediatas de uma certa comunidade científica. Nesse sentido, a história oficial é utilizada como uma formulação discursiva que tenta oferecer aos cientistas uma narrativa histórica em relação à significância de um dado objeto.

O artigo “A Sociological Study of the Official History of the Perceptrons Controversy”, de Mikel Olazaran, analisa o livro *Perceptrons*, de Minsky e Papert, enquanto um objeto cognitivo em disputa, no sentido dado por Pinch.²⁷ Olazaran traça a emergência desses dois modos de articulação, demonstrando como a institucionalização do modo histórico-oficial foi taticamente endossada por pesquisadores na área de IA simbólica, por eles acreditarem que recursos estavam sendo retirados de sua área e redirecionados a pesquisas conexionistas. O modo da área de pesquisa estava em concordância com

27 Olazaran, Mikel. “A Sociological Study of the Official History of the Perceptrons Controversy,” *Social Studies of Science*, 26, no. 3, 1996. pp. 611–59, <https://doi.org/10.1177/030631296026003005>.

alguns dos pontos fundamentais do modo de articulação histórico sobre o objeto em disputa: que Minsky e Papert haviam demonstrado a limitação do perceptron no que diz respeito a reconhecimento de padrões e execução da função XOR. O modo da área de pesquisa, no entanto, divergia rapidamente da história oficial quando nos atentamos ao que o livro dizia de fato versus as interpretações a respeito dos perceptrons de camadas-múltiplas. Adicionalmente, o modo de articulação da área de pesquisa não atribuía a mesma importância à publicação do livro no que diz respeito ao financiamento de pesquisas em IA conexionista.

A história oficial articulada pressupunha que Minsky e Papert demonstraram que a pesquisa em redes neurais devia ser abandonada em função de suas limitações matemáticas intrínsecas, e que o financiamento dos projetos conexionistas eram um gasto fútil a ser redirecionado para pesquisas em IA simbólica, no campo oposto. Minsky e Papert teriam formulado que as limitações no perceptron de camada-única eram encontradas no treinamento dos perceptrons de camadas múltiplas. O modo de história oficial vê essa especulação como algo fechado: Olazaran usa o termo “prova de impossibilidade”, afirmando que o livro *Perceptrons* foi interpretado como “uma prova cabal da impossibilidade dos perceptrons”.²⁸ O modo de história oficial nesse sentido comete dois erros. Primeiro, ele interpreta o livro de Minsky e Papert como bem-sucedido em demonstrar que o perceptron de Rosenblatt possuía dificuldades insuperáveis. Segundo, que a publicação do livro *Perceptrons*, em 1969, teria destruído o

28 Ibid., p. 629.

campo de pesquisa em redes neurais em sua totalidade.

Esse modo de história oficial é visível em muito do pensamento crítico recente em tecnologia. Num ensaio de 2017 amplamente citado, “Machines That Morph Logic”, de Matteo Pasquinelli, o autor cegamente reitera essa narrativa oficial, afirmando que a mera publicação “teve um impacto devastador” e que “bloqueou financiamentos para a área de pesquisa de redes neurais por décadas”.²⁹ Michael Castelle, em seu livro *Deep Learning as an Epistemic Ensemble*, também relaciona a publicação do livro com a morte das redes neurais, afirmando que o interesse nelas só retornou lentamente no meio dos anos 80, mas nunca na escala em que existia antes da publicação do livro, sobretudo devido ao advento de sistemas mais complexos de machine learning.³⁰ Ambos os pensadores estão presos a um modo de articulação que não permite flexibilidade interpretativa. Para eles, o objeto em disputa faz parte de uma narrativa fechada.

Minsky e Papert de fato estavam “dispostos a matar o perceptron”.³¹ Porém, de acordo com o modo da área de pesquisa, ainda que Minsky e Papert tivessem apontado para dificuldades encontradas no treinamento de perceptrons de múltiplas camadas, estas eram meramente dificuldades que já haviam sido reconhecidas por estudiosos de IA conexionista, mas nunca haviam sido consideradas insolucionáveis. Esse problema, portanto, oferece uma certa flexibilidade

29 Pasquinelli, Matteo. “Machines That Morph Logic: Neural Networks and the Distorted Automation of Intelligence as Statistical Inference,” *Glass Bead*, no. 1, 2017.

30 Castelle, Michael. “Deep Learning as an Epistemic Ensemble,” 15 de setembro de 2018, <https://castelle.org/pages/deep-learning-as-an-epistemic-ensemble.html>.

31 Bernstein, Jeremy. “Profiles: A.I.,” *New Yorker*, 14 de dezembro de 1981, <https://www.newyorker.com/magazine/1981/12/14/a-i>.

interpretativa no modo de articulação de certa área de pesquisa. Muitos pesquisadores conexionistas, e mesmo Rosenblatt de forma substancial, discutiram as dificuldades de aprendizado em perceptrons com múltiplas camadas. Rosenblatt, em *Principles of Neurodynamics* – publicado oito anos antes do *Perceptrons* de Minsky e Papert – faz questão de delimitar muitos dos obstáculos a serem encontrados em um perceptron com múltiplas camadas, obstáculos também mencionados por Minsky e Papert.³² Mais importante, Rosenblatt não encara esses problemas como insuperáveis mas apenas como obstáculos que necessitam de mais pesquisa para serem ultrapassados. Bernard Widrow, outro importante pesquisador de IA no paradigma conexionista de seu tempo, chama atenção para o fato de que muitas das pesquisas realizadas no campo dos perceptrons com múltiplas camadas já havia superado várias das limitações indicadas na publicação de *Perceptrons*.³³

Para o modo de articulação das pesquisas de área, o efeito da publicação nas pesquisas em IA conexionista também está aberto a esta mesma flexibilidade interpretativa. Os argumentos de Minsky e Papert circularam em forma de manuscritos muito antes da publicação formal do livro em 1969. Jack Cowan relembra que em 1962 a pesquisa em redes neurais já estava perdendo certa tração, o que se devia apenas parcialmente às críticas delas.³⁴ Essa afirmação parece estar de acordo com a afirmação de Widrow de que em 1969 a pesquisa conexionista já havia avançado para muito além do modelo do perceptron criticado em *Perceptrons*: os argumentos de Minsky e Papert

32 Rosenblatt, *Principles of Neurodynamics*, pp. 577–81.

33 Olazaran, "A Sociological Study of the Official History of the Perceptrons Controversy," p. 634.

34 Anderson e Rosenfeld, *Talking Nets*, p. 108

eram baseados em modelos do início dos anos 1960. Além disso, a pesquisa em redes neurais não havia sido interrompida em sua totalidade durante o chamado “inverno da IA”; ela simplesmente foi feita fora do campo de IA.³⁵ Ainda que esse movimento tenha sido mais prevalente na Europa do que nos EUA, pensar em um completo abandono das redes neurais após a publicação do livro é um exagero que está especificamente ligado ao modo de articulação de histórias oficiais. Assim, na articulação das pesquisas na área, a publicação do livro teve um impacto bem menos profundo e dramático do que o modo de articulação dessa história oficial deixa transparecer.

Conexionismo

Mesmo que o discurso contemporâneo quanto ao *deep learning* frequentemente oculte a natureza fundamentalmente conexcionista das redes neurais complexas, o esquema básico do perceptron – no qual neurônios recebem energia de um campo retinal e geram uma resposta baseada em vieses e ponderações aprendidas – é ainda o formato básico para sistemas de *machine-learning*. As redes neurais profundas de hoje em dia são essencialmente conexcionistas; essas tecnologias ainda se enquadram nos mesmos fundamentos articulados por Rosenblatt.

35 Olazaran, “A Sociological Study of the Official History of the Perceptrons Controversy,” pp. 641–42.

Em 1987, David Rumelhart e James McClelland publicaram o primeiro de seus livros sobre Processamento Paralelamente Distribuído (PDP), citando o conexionismo de Rosenblatt como uma influência direta.³⁶ Apesar de sua pesquisa ter permanecido relativamente marginal à época, ela inspirou um ressurgimento no interesse por redes neurais em um tempo no qual, devido à institucionalização do modo oficial da história, o conexionismo estava desacreditado no campo da IA.³⁷ Rumelhart e McClelland continuaram a pesquisa baseada em neurofisiologia de Rosenblatt, tomando o neurônio como unidade cognitiva fundamental. Eles viam a capacidade do cérebro humano de processar informação como se originando de seu paralelismo: a habilidade de realizar múltiplas tarefas ao mesmo tempo. Eles buscaram atualizar a pesquisa de Rosenblatt para que esta pudesse ser adaptada a desenvolvimentos em computação que permitissem formas de processamento paralelo. O grupo de PDP cresceu e passou a incluir pesquisadores de outros campos, como Geoffrey Hinton e Terrence Sejnowski. Esse grupo expandido introduziu a máquina de Boltzmann e o algoritmo de retropropagação, que ainda hoje é largamente usado.

O perceptron, assim, além de ser o precursor técnico das contribuições de PDP, pode ser visto como uma necessidade conceitual que embasa toda a cultura contemporânea de machine-learning. O livro *Machine Learners: Archaeology of a Data Practice*, de Adrian Mackenzie, usa o perceptron enquanto um diagrama para a prática dos programadores de

36 Rumelhart, David E.; McClelland, James L.; e o PDP Research Group, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Volume 1: Foundations. Cambridge, Massachusetts: The MIT Press, 1999.

37 Boden, *Mind as Machine*, p. 943–48.

machine-learning.³⁸ No texto de Mackenzie, o perceptron sintetiza os recursos advindos de um relacionamento dinâmico de trabalho com dados. O processo relativamente simples de ensinar um perceptron a operação booleana NAND demonstra a necessidade de adaptação às gramáticas de ação e demandas de bancos de dados por parte dos programadores, em um cenário no qual os dados modificam e refazem a operação realizada neles. Em oposição a um espaço de dados estático como o da taxonomia de Lineu, programadores tratam dados como operações de funções numéricas ou vetores. Por esse motivo, muitos dos livros e manuais de *machine-learning* introduzem o perceptron logo no início: programadores devem se familiarizar com os recursos e movimentos dessa rede neural relativamente simples, já que esses recursos serão subsequentemente transpostos para sistemas mais complexos. Dessa forma, o perceptron é o arquétipo central do *machine-learning* contemporâneo.

Um bom exemplo de como a arquitetura do perceptron informa modelos contemporâneos de classificação de imagens são as redes neurais convolucionais (CNNs). As CNNs possuem três características fundamentais: uma camada convolucional que engloba uma série de filtros, uma camada que possui uma unidade linear retificada (RELU) que atua de maneira análoga aos neurônios, uma camada de *pooling* para a redução de dimensionalidade, e uma camada *fully connected* (FC) que classifica padrões tendo como base uma pequena amostra de dados rotulados.³⁹ Cada filtro da camada

38 Mackenzie, Adrian. *Machine Learners: Archaeology of a Data Practice*. Cambridge, Massachusetts: The MIT Press, 2017. pp. 21–50.

39 Para o artigo original de Yann Lecun, cf. Yann LeCun et al., "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE* 86, no. 11, 1998. pp. 2278–324.

convolucional é idêntico ao campo retinal único do perceptron: um filtro é composto de uma rede de unidades-S, cada uma das quais se foca em uma área particular de um plano, um filtro que procura por um certo padrão. A camada convolucional transmite estímulos para a camada RELU dependendo se o padrão de um certo filtro é encontrado ou não, ou seja, essa camada atua de maneira análoga às unidades-A. A camada de *pooling* é necessária justamente para gerenciar a grande quantidade de dados, e não está presente no perceptron devido a sua simplicidade. A camada convolucional, camada RELU e a camada de *pooling* podem aparecer múltiplas vezes em várias sequências até se conectarem à camada final, a camada FC. A camada FC é similar à camada-R de Rosenblatt, já que, tal como ela, aprende a classificar com base em exemplos e em feedbacks de tentativa-e-erro.

O perceptron pode, portanto, ser visto como a fundação sobre a qual os sistemas de *machine-learning* que conhecemos hoje em dia são construídos. Uma transformação significativa que ocorreu nessa passagem do perceptron aos esquemas complexos de redes neurais é o fato de que os novos sistemas possuem relações dinâmicas com seus índices. Para o perceptron Mark I de Rosenblatt, a meta do sistema era realizar uma indexação entre forma e conjunto de dados, estabelecendo uma correspondência direta entre um objeto real e as unidades-A do perceptron. Se a equipe de Rosenblatt pudesse fazer uma afirmação indexical, isso seria demonstrativo de que seu dispositivo tinha alguma capacidade de interagir com o mundo. Michael Castelle, no entanto, aponta que no século XXI muito da utilidade funcional dos sistemas de *deep learning*

reside na capacidade destes em realizarem uma transdução entre índice e símbolo.⁴⁰

No caso das CNN's, a rede entra em contato com um objeto do mundo real através de um banco de dados como o ImageNet e utiliza operações simbólicas a fim de formar uma captura textual – uma representação simbólica do objeto – que descreva o conteúdo desses dados. Essa transdução entre índice e símbolo, a aplicação principal das redes neurais, não poderia ocorrer caso o perceptron não fosse o diagrama fundamental para essas operações. O perceptron pode ser situado como a matriz através da qual surgem as redes neurais profundas de alta complexidade. Dessa forma, os modelos onipresentes de classificação de imagens, como as redes neurais convolucionais, devem ser considerados resultantes da ontogenia do perceptron.

40 Castle, "Deep Learning as an Epistemic Ensemble."