

Utilização de *deep learning* em ações de controle



Luís André Dutra e Silva

é auditor do Tribunal de Contas da União, Bacharel em Ciência da Computação pelo UniCeub, com certificação em Engenharia de Software pelo IEEE e em Gestão de Projetos pela Universidade Stanford, lotado na Secretaria de Soluções de TI.

RESUMO

Este artigo descreve como a técnica de *deep learning* pode ser aplicada em ações de controle externo e no combate à corrupção. São apresentados fatos históricos que marcaram a evolução dessa técnica, o funcionamento das redes neurais artificiais e biológicas, bem como um conjunto de exemplos de aplicação.

Palavras-chave: machine learning, deep learning, redes neurais, combate à corrupção, ações de controle, algoritmos.

1. INTRODUÇÃO

Entre as técnicas de *machine learning* (vertente do corpo de conhecimentos sobre inteligência artificial baseada em algoritmos que utilizam um grande número de exemplos para o treinamento de modelos computacionais), *deep learning* está em destaque nos últimos anos. Trata-se de um conjunto de técnicas que utilizam redes neurais artificiais profundas, com muitas camadas intermediárias entre a camada de entrada e a de saída (LECUN et al., 2015).

O diferencial tecnológico dessa abordagem está nos excelentes resultados obtidos na resolução de problemas, resultados esses que superam até mesmo o desempenho dos melhores especialistas em determinadas áreas de conhecimento, como, por



exemplo, o reconhecimento de localidades e características semânticas em imagens, a vitória em jogos de estratégia mais complexos do que o xadrez e a superação de seres humanos em testes psicométricos de compreensão verbal.

A seguir é apresentado um breve histórico dessa técnica e sua aplicação nas ações de controle e no combate à corrupção, assim como uma descrição do funcionamento das redes neurais.

2. HISTÓRICO

Os modelos conexionistas de aprendizado automático foram inicialmente implementados pela indústria durante a década de 1950 em decorrência do surgimento de sistemas computacionais de grande porte. As primeiras tentativas de implementação desses modelos, no entanto, não foram bem-sucedidas devido a limitações do poder de processamento dos computadores daquela época, associadas à falta de embasamento teórico que suportasse a execução da técnica. Entre as iniciativas fracassadas, podemos citar a simulação de “cérebros eletrônicos” por Nathaniel Rochester dos laboratórios de pesquisa da IBM.

Outro fator que contribuiu para a redução de interesse da comunidade científica por esse tema foi a publicação, em 1969, de um artigo do cientista norte-americano Marvin Minsky, o qual demonstrava que o *perceptron*, o mais primitivo neurônio artificial,

seria inadequado para reproduzir todas as operações lógicas básicas como, por exemplo, o “ou exclusivo”, função lógica essencial para a resolução de equações booleanas.

Não obstante as dificuldades experimentadas, em meados da década de 1970, com a melhoria do poder de processamento dos computadores, surgiu um novo algoritmo, denominado *backpropagation* (WERBOS, 1974), o qual demonstrou a possibilidade de os modelos conexionistas reproduzirem fielmente todas as operações lógicas efetuadas pela mente humana, dependendo somente do número de neurônios artificiais utilizados e do número de camadas projetadas para determinadas finalidades.

Paralelamente ao esforço dos cientistas e engenheiros em imitar os mecanismos biológicos da inteligência, no final dos anos 1970 o neurocientista Vernon Benjamin Mountcastle chegou a uma descoberta fundamental para essa questão: ele demonstrou que o neocórtex possui um único algoritmo de aprendizado, que se repete em todas as regiões do cérebro em estruturas colunares (MOUNTCASTLE, 1978).

Apesar da disponibilidade de algoritmos de redes neurais durante a década de 1980, somente em meados da década de 1990 surgiram as primeiras pesquisas que utilizaram essa técnica aplicada à análise de fraudes corporativas. Kurt Fanning (1995) demonstrou que redes neurais auto-organizáveis podem ser usadas para a predição de fraudes em relatórios financeiros de empresas.

Na década seguinte houve grande avanço dos dispositivos de computação paralela de baixo custo, fato que possibilitou o treinamento de modelos altamente complexos em um tempo infinitesimalmente menor do que anteriormente disponível por meios sequenciais. Em 2004, Jeff Hawkins (2004), ex-engenheiro da Intel e fundador da Palm Inc., argumentou que as estruturas descobertas por Mountcastle funcionam como pequenos reconhedores de padrões, que podem ser interconectados de forma a aprender qualquer conceito e mesmo a realizar previsões e generalizações sobre algo não experimentado. Além disso, nessa década novas formas de inicialização de parâmetros causaram grande entusiasmo nos proponentes de *deep learning*, técnica antes vista apenas como limitada à memorização de dados e incapaz de generalizar suas predições.

Após o ano de 2010, surgiram inúmeros artigos científicos demonstrando a aplicabilidade de modelos neurais que auxiliam as grandes organizações em suas ações de governança corporativa por meio da detecção de fraudes em operações financeiras.

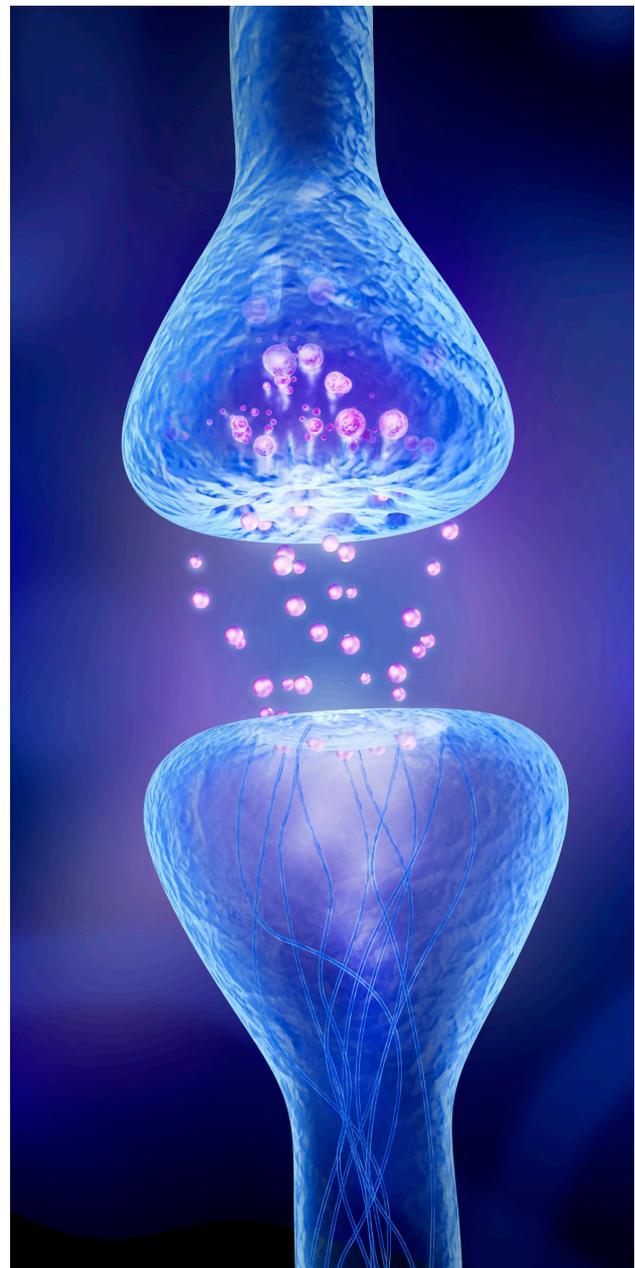
Alguns anos depois, em 2012, a teoria de Hawkins foi reforçada por Kurzweil, que demonstrou que os modelos conexionistas, quando conjugados a modelos estatísticos, detectam padrões temporais e implementam a ideia central da organização em camadas hierárquicas, necessárias aos reconhedores de padrões similares aos descobertos por Mountcastle.

Para a finalidade da previsão de atividades irregulares, o treinamento de modelos artificiais baseados em sua contraparte biológica, na maioria das vezes, ocorre sem supervisão, de forma que os neurônios ativos, que representam os conceitos aprendidos, são determinados competitivamente e não podem ser diretamente traduzidos em algo que já se conhece previamente, mas necessitam da ajuda de especialistas para determinar os significados emergentes de tal processo de aprendizado.

Assim, suas aplicações mais diretas são na detecção de anomalias de forma online e na elaboração de conceitos que, tradicionalmente, estariam fundamentados nos métodos de Inteligência Artificial, disponíveis em grande escala desde a década de 1960, para o combate às fraudes corporativas, e não em técnicas de *deep learning* baseadas em um grande número de exemplos reais e contínuos.

Mais recentemente, em 2014, surgiram métodos de descarte aleatório de conexões, os quais

inserem o ruído necessário à não ocorrência de simples memorização, possibilitando a construção de modelos com performance exponencialmente superior aos anteriores, em termos de generalização de comportamento (HINTON et al, 2014). Esse método de descarte de conexões tem como motivação o processo que ocorre na reprodução sexuada, em que os genes do casal são combinados com uma pequena mutação aleatória no código genético transmitido hereditariamente, sendo este o meio mais eficiente na evolução dos organismos vivos mais avançados.



3. FUNCIONAMENTO

Em 1981, Mountcastle recebeu o prêmio Nobel de Medicina pela descoberta (considerada a Pedra de Roseta da neurociência) de que a estrutura fundamental do neocórtex cerebral é uma minicolumna com cerca de uma centena de neurônios dispostos em seis camadas distintas e que o cérebro humano possui cerca de 100.000.000 dessas pequenas estruturas em toda a sua extensão (MOUNTCASTLE, 1978). Existem conexões em ambos os sentidos, o que significa, conseqüentemente, que a unidade básica de nosso cérebro é uma rede recorrente e modularizada, pois cada uma das minicolumnas conecta-se a centenas de outras similares, formando uma coluna de até 70.000 neurônios, cujo tamanho aproximado é comparável ao de uma cabeça de alfinete. As colunas agrupam-se para formar tecidos especializados em determinada função cognitiva, e esses tecidos, por sua vez, podem estar conectados a qualquer outro módulo, não importando a distância que os separe, pois existem axônios que podem ir de um extremo a outro do cérebro.

Segundo Hawkins (2004), a camada inferior do neocórtex possui um número muito maior de conexões (sinapses) com terminais provenientes de axônios de outras regiões do sistema nervoso do que conexões que se originam dessa camada. Dessa forma, o nível de representação que a primeira camada oferece está ligado a eventos temporais provenientes dos sentidos. A partir da segunda camada, entretanto, são formados conceitos progressivamente persistentes e independentes de mudanças temporais. Por último, a ativação de neurônios da sexta camada ocorre sempre que padrões estejam presentes nas conexões de entrada e tais ativações persistem enquanto durar a exposição a esses padrões.

Em conformidade com sua função cognitiva de representar conceitos persistentes, a sexta camada possui um número muito maior de terminais saindo do que o número de sinapses ligadas a dendritos que se conectam a essa camada. Além disso, um número muito pequeno de neurônios da sexta camada é ativado para determinado conceito e, empiricamente, foi comprovado que sempre os mesmos neurônios são ativados para algum conceito em particular (ZADOR, 2000). Essa demonstração foi realizada em uma experiência científica em que pessoas sujeitas ao monitoramento do cérebro por ressonância nuclear magnética, ao vi-

sualizar a fotografia de uma determinada pessoa, tinham sempre a ativação dos mesmos neurônios da sexta camada.

Além disso, a presença simultânea de padrões diferentes em regiões distintas do neocórtex na primeira camada faz com que esses padrões reforcem os pesos (sinapses) que os associam. Sendo assim, o neocórtex funciona como uma memória associativa em que um padrão, ou parte dele, ativa os neurônios que representam padrões correlatos. De acordo com essa arquitetura associativa, a função das conexões de neurônios da sexta camada para as outras é a de realizar predições sobre quais padrões sucederão os que se encontram presentes nas conexões imediatamente inferiores, reforçando a seqüência de eventos previstos que foram aprendidos pela experiência.

É importante considerar, também, o fato de que a estrutura hierárquica das camadas do córtex visual inspirou a criação de redes neurais convolucionais (CNNs). Esse tipo de implementação demonstrou ser a mais adequada para o reconhecimento de padrões visuais (LECUN, 1995). Existe, no entanto, uma diferença fundamental entre CNNs e redes neurais biológicas: CNNs são geralmente unidirecionais (FFNs), enquanto que as redes neurais naturais são recorrentes (RNNs).

Em outra frente de pesquisa, relacionada a uma arquitetura mais próxima da realidade, as redes neurais artificiais recorrentes, assim como o neocórtex, são estimuladas primariamente por padrões



temporais (GRAVES, 2012). Assim, a sequência de estímulos sucessivos permite que sejam classificados automaticamente de forma que possam ser associados a outras sequências previamente aprendidas. É um fato comprovado, nesse caso, a necessidade que a mente humana possui de aprender padrões sequenciais. Por exemplo, a sequência de notas de uma melodia pode ser facilmente lembrada; no entanto, dificilmente a nossa mente consegue recordar a sequência inversa das notas musicais.

Essa limitação não ocorre em redes neurais artificiais, pois modelos recorrentes bidirecionais (BRNN) podem aprender qualquer sequência temporal ou espacial em ambos os sentidos. Tais modelos são comprovadamente mais eficientes no reconhecimento de sequências tais como a fala, a escrita e os eventos sucessivos que podem estar relacionados a alguma irregularidade ou atividade ilícita.

4. APLICAÇÕES EM AÇÕES DE CONTROLE

Como exemplo de uma aplicação em bases textuais, uma simples rede neural tradicional (*Multi Layer Perceptron*) com poucas camadas intermediárias é capaz de classificar com alta precisão tipos de deliberações contidos em acórdãos proferidos pelo Tribunal. Essa classificação é fundamental para a delimitação de um contexto para a posterior extração dos atributos (entidades nomeadas) das diversas deliberações que precisam ser continuamente monitoradas pelos especialistas.

Considerando outro extremo, uma aplicação em bases fotográficas, com a finalidade de abranger um grande número de obras fiscalizadas, as redes neurais convolucionais podem ser utilizadas para monitorar, usando imagens obtidas por sensoriamento remoto, o andamento da execução dos projetos. Esse tipo de aplicação pode realizar a comparação das imagens referentes aos diversos estágios de cada obra e indicar possíveis atrasos ou inconformidades técnicas com as especificações.

Quando se trata da detecção de anomalias aplicada ao descobrimento de fraudes em convênios, por exemplo, uma rede neural artificial pode, em modo não supervisionado, reconhecer situações anormais em sua execução após receber como entrada milhares de situações normais que não representam irregularidades. Assim, caso ocorra uma discrepância entre os fluxos de recursos realizados e a execução espe-

rada dos projetos, esse método pode indicar, com alta probabilidade, a ocorrência de atividades ilícitas.

No caso de tratamento de sequências, uma rede recorrente pode ser treinada com as séries temporais de ofertas de preços e atributos dos objetos de licitações, aprendendo a identificar sequências que representam irregularidades no processo licitatório. Isso é possível graças ao grande número de exemplos existentes de sequências anteriores, que foram classificadas como irregulares ou não por especialistas. Sendo assim, esse tipo de solução conteria o conhecimento consolidado de muitos profissionais ao longo de décadas de experiência.

Redes neurais também podem ser utilizadas para o encaminhamento e a classificação de irregularidades em processos de Tomada de Contas Especial, por meio do reconhecimento de padrões textuais e lógicos em documentos provenientes de diversas fontes de dados não estruturados. Esse processo consiste na realização de treinamentos não supervisionados, feita em uma grande quantidade de documentos com a finalidade de encontrar agrupamentos semânticos que posteriormente podem ser associados a grupos de irregularidades em tais processos. Após a associação de tais agrupamentos aos significados identificados por especialistas, é possível criar modelos neurais supervisionados capazes de realizar o mesmo tipo de classificação e encaminhamento de novos documentos que não fizeram parte do treinamento inicial.

5. CONCLUSÃO

O uso de soluções de *deep learning* no auxílio ao combate à corrupção, portanto, pode acarretar um ganho de escala suficiente para abranger um número muito maior de casos de irregularidades do que hoje é possível atingir por simples amostragem relacionada à materialidade dos recursos envolvidos. No entanto, certamente, o papel dos especialistas de cada área envolvida não poderá ser dispensado, uma vez que as situações encontradas automaticamente não representam indicações determinísticas, mas indicações com uma probabilidade associada ao maior ou menor grau de certeza de que representam achados importantes a serem fiscalizados pelo TCU e outros órgãos de controle.

REFERÊNCIAS

MINSKY, Marvin; PAPERT, Seymour. *Perceptrons: An Introduction to Computational Geometry*. Cambridge: The MIT Press, 1969.

WERBOS, Paul J. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Cambridge MA: Harvard University Press, 1974.

MOUNTCASTLE, Vernon B. *An Organizing Principle for Cerebral Function: The Unit Model and the Distributed System*. Cambridge: MIT Press, 1978.

LECUN, Y; BENGIO, Y. Convolutional Networks for Images, Speech, and Time-Series. *The Handbook of Brain Theory and Neural Networks*. Cambridge: MIT Press, 1995.

FANNING, K.; COGGER, K.O.; SRIVASTAVA, R. *Detection of Management Fraud: A Neural Network Approach*. New York: IEEE, 1995

ZADOR, Anthony. *Neural Representation and The Cortical Code*. San Francisco: Annual Reviews, 2000.

HAWKINS, Jeff; BLAKESLEE, Sandra. *On Intelligence*. New York: Times Books, 2004.

LIVNAT, A; PAPADIMITRIOU, C.; PIPPENGER, N., FELDMAN, M.W. Sex, mixability, and modularity. *Proceedings of the National Academy of Sciences*. Redwood City: Highwire Press, 2010. Volume 107. p. 1452–1457.

KURZWEIL, Ray. *How to Create a Mind: The Secret of Human Thought Revealed*. New York: Viking Books, 2012.

GRAVES, Alex. *Supervised Sequence Labelling with Recurrent Neural Networks*. New York: Springer 2012.

HINTON, Geoffrey; SRIVASTAVA, Nitish; KRIZHEVSKY, Alex; SUTSKEVER, Ilya; SALAKHUTDINOV, Ruslan. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. Brookline: Microtome Publishing, 2014. Volume 15. p. 1929-1958.

LECUN, Y; BENGIO, Y; HINTON, G. Deep learning. *Nature*. New York: Macmillan Publishers Limited, 2015. Volume 521. p. 436-444.

