

As Redes Neurais Artificiais e o Ensino da Medicina

Artificial Neural Networks and Medical Education

Rodrigo Siqueira-Batista^I
Rodrigo Roger Vitorino^{II}
Andréia Patrícia Gomes^{III}
Alcione de Paiva Oliveira^{III}
Ricardo dos Santos Ferreira^{III}
Vanderson Esperidião-Antonio^{III}
Luiz Alberto Santana^{III}
Fabio Ribeiro Cerqueira^{III}

PALAVRAS-CHAVE

- Educação Médica;
- Redes Neurais Artificiais;
- Medicina.

KEYWORDS

- Medical Education;
- Artificial Neural Networks;
- Medicine.

RESUMO

As transformações da prática médica nos últimos anos – sobretudo com a incorporação de novas tecnologias da informação – apontam a necessidade de ampliar as discussões sobre o processo ensino-aprendizagem na educação médica. A utilização de novas tecnologias computacionais no ensino médico tem demonstrado inúmeras vantagens no processo de aquisição de habilidades para a identificação e a resolução de problemas, o que estimula a criatividade, o senso crítico, a curiosidade e o espírito científico. Nesse contexto, ganham destaque as Redes Neurais Artificiais (RNA) – sistemas computacionais cuja estrutura matemática é inspirada no funcionamento do cérebro humano –, as quais têm sido úteis no processo ensino-aprendizagem e na avaliação de estudantes de Medicina. Com base nessas ponderações, o escopo da presente comunicação é revisar aspectos da aplicação das RNA na educação médica.

ABSTRACT

The transformations that medical practice has undergone in recent years – especially with the incorporation of new information technologies – point to the need to broaden discussions on the teaching-learning process in medical education. The use of new computer technologies in medical education has shown many advantages in the process of acquiring skills in problem solving, which encourages creativity, critical thinking, curiosity and scientific spirit. In this context, it is important to highlight artificial neural networks (ANN) – computer systems with a mathematical structure inspired by the human brain – which proved to be useful in the evaluation process and the acquisition of knowledge among medical students. The purpose of this communication is to review aspects of the application of ANN in medical education.

Recebido em: 28/03/2013

Reencaminhado em: 20/04/2014

Aprovado em: 20/08/2014

^I Universidade Federal de Viçosa, Viçosa, MG, Brasil; Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ; Brasil.

^{II} Pontifícia Universidade Católica de Campinas, Campinas, SP, Brasil.

^{III} Universidade Federal de Viçosa, Viçosa, MG; Brasil.

INTRODUÇÃO

As diversas *faces* da medicina – as questões da prevenção e do cuidado, da *episteme*/conhecimento e da técnica/arte, da razão e da intuição – vêm *caminhando* juntas no Ocidente desde seu nascimento na Grécia antiga¹. O avanço tecnológico vivenciado nos últimos cem anos tem tornado cada vez mais necessários os debates acerca das relações entre medicina e biotecnociência² – com destaque para as questões atinentes ao acesso às novas informações. Tais debates devem envolver generalistas e especialistas, que lidarão (na verdade, em muitas circunstâncias, já vêm lidando...), em um futuro breve, com inúmeros avanços – há pouco inimagináveis –, incluindo novas modalidades de transplantes, cirurgias minimamente invasivas, nanomedicina, telemedicina e cirurgia robótica^{3,4}. Certamente, essas fronteiras surgem como possibilidades de maximização da qualidade do cuidado oferecido aos enfermos, dimensão almejada por aqueles que exercem – com arte, zelo e comprometimento humano e social – a medicina.

Como em qualquer *techne/episteme*⁵, o progresso e o ato de encontrar respostas trazem, a reboque, um emaranhado de novas perguntas, que antes sequer poderiam ser formuladas. Torna-se, com efeito, fundamental abordar a educação médica no âmbito das transformações biotecnocientíficas contemporâneas, discutindo conceitos relevantes na atualidade, mesmo que pareçam distantes para o colega que exerce a profissão cotidianamente.

Nesse âmbito, as Redes Neurais Artificiais (RNA) – uma forma de computação não algorítmica, caracterizada por sistemas que, em certo grau, se assemelham à estrutura do cérebro humano^{6,7} – ganham relevância em razão de suas potencialidades para a medicina. As RNA constituem sistemas paralelos e distribuídos, compostos por unidades de processamento simples – geralmente denominados neurônios artificiais, em analogia aos neurônios biológicos –, dispostas em uma ou mais camadas e interligadas por múltiplas conexões⁸.

Sua arquitetura possibilita um desempenho extraordinário, pois o processo usual de resolução de problemas é fundamentado na aprendizagem e nas generalizações, que são proporcionadas pela adaptação de seus parâmetros a um conjunto de padrões previamente apresentados⁹. A capacidade de generalizar – ou seja, aprender por meio de um conjunto de exemplos e dar respostas coerentes a dados não conhecidos – torna possível a resolução de problemas computacionais complexos⁸.

O excelente desempenho das RNA – as quais, para diversas classes de problemas, se mostram muito superiores

aos modelos computacionais convencionais – tem contribuído para o avanço de diversos campos de atuação na prática clínica¹⁰. Como exemplos de resultados significativos da aplicação de RNA em problemas da área médica, podem-se citar: auxílio no diagnóstico de doenças, predição de riscos e prognóstico, interpretação de métodos diagnósticos, desenvolvimento das pesquisas epidemiológicas, dentre outros^{11,12}.

Com base nestas breves considerações, o objetivo da presente comunicação é apresentar uma revisão da literatura acerca das aplicações das RNA na educação médica.

MÉTODOS

O presente trabalho foi construído tendo por base a revisão da literatura com estratégia de busca definida. Foram consultadas a U. S. National Library of Medicine (PubMed) e a Scientific Electronic Library Online (SciELO), no período de 01/01/1990 a 31/12/2013. Os termos utilizados foram:

- Estratégia 1: educação médica (*medical education*) + redes neurais artificiais (*artificial neural networks*);
- Estratégia 2: redes neurais artificiais (*artificial neural networks*);
- Estratégia 3: redes neurais artificiais (*artificial neural networks*) + medicina (*medicine*).

Além dos artigos, foram consultados livros-textos, teses de doutorado, dissertações de mestrado, diretrizes e documentos oficiais relacionados ao tema – mais especificamente à educação médica e ao campo da saúde.

A pesquisa empreendida permitiu identificar 3.578 citações – cuja distribuição se encontra no Quadro 1 –, dentre as quais foram selecionados 35 manuscritos, utilizando-se como critério de elegibilidade a apresentação da aplicação da RNA no ensino da Medicina.

QUADRO 1:
Número de artigos obtidos na pesquisa bibliográfica

Estratégia de busca*	Base consultada	
	Pubmed*	SciELO Brasil
Estratégia 1 – “educação médica” + “redes neurais artificiais”	3	0
Estratégia 2 – “redes neurais artificiais”	3.217	50
Estratégia 3 – “redes neurais artificiais + medicina”	308	0

* Data-limite da busca: 31/12/2013.

RESULTADOS E DISCUSSÃO

Após leitura e análise dos textos obtidos, os apontamentos coligidos foram organizados em três seções – educação médica e as novas tecnologias; redes neurais artificiais; redes neurais artificiais: usos na educação médica –, apresentadas a seguir.

EDUCAÇÃO MÉDICA E AS NOVAS TECNOLOGIAS

A Constituição Federal¹³, promulgada em 5 de outubro de 1988, possui marcante dimensão progressista no que se refere à saúde, enunciada especialmente no Artigo 196, que dispõe sobre o papel do Estado, nos seguintes termos:

A saúde é um direito de todos e um dever do Estado, garantido mediante políticas sociais e econômicas, que visem à redução do risco de doença e de outros agravos e ao acesso universal e igualitário às ações e serviços para sua promoção, proteção e recuperação. (p.33)

Nesse mesmo movimento de vanguarda é criado o Sistema Único de Saúde (SUS)¹⁴, tendo como alicerce o Artigo 198, o qual explicita que¹³:

As ações e serviços públicos de saúde integram uma rede regionalizada e hierarquizada e constituem um sistema único, organizado de acordo com as seguintes diretrizes:

I – descentralização, com direção única em cada esfera de governo;

II – atendimento integral, com prioridade para as atividades preventivas, sem prejuízo dos serviços assistenciais;

III – participação da comunidade. (p. 33. 34)

A fim de estabelecer parâmetros que garantam, exatamente, a formação de um profissional apto a oferecer os serviços de qualidade preconizados, a Resolução CNE/CES nº 4, de 7 de novembro de 2001, que institui as Diretrizes Curriculares Nacionais do Curso de Graduação em Medicina¹⁵, em seu Artigo 3º, propõe o perfil:

O Curso de Graduação em Medicina tem como perfil do formando egresso/profissional o médico, com formação generalista, humanista, crítica e reflexiva, capacitado a atuar, pautado em princípios éticos, no processo de saúde-doença em seus diferentes níveis de atenção, com ações de promoção, prevenção, recuperação e reabilitação à saúde, na perspectiva da integralidade da assistência, com senso de responsabilidade social e compromisso com a cidadania, como promotor da saúde integral do ser humano. (p.1)

Para o alcance dos objetivos, deve-se ter clareza quanto às necessidades de ampliação das habilidades imprescindíveis à atual realidade do mundo do trabalho, que, em um contexto globalizado – de informações rapidamente difundidas e de uma ciência cada vez mais complexa –, exige competências diversas das anteriormente arroladas para o exercício da profissão¹⁶. Não se trata exclusivamente de habilidades para o trabalho médico, mas, também, de capacidades pertinentes a todos os profissionais da área de saúde, como uma nova postura de interpretar a realidade, lidar com conceitos científicos e usufruir de potencialidades tecnológicas de modo responsável, condições indispensáveis para acompanhar o ritmo acelerado de avanços da sociedade.

Educar é essencialmente formar^{17,18}. Logo, o papel do educador e das instituições de educação, certamente, não se restringe à oferta de informação e, tampouco, à redução da experiência educativa a puro treinamento técnico¹⁷. Compete ao homem/mulher que ensina-aprende a outro homem/mulher a construção de uma genuína relação sujeito-sujeito, educador-educando¹⁹. É a *práxis*, que implica a ação e a reflexão dos homens/mulheres sobre o mundo, para transformá-lo. Surgem, então, espaços para novas metodologias de ensino-aprendizagem e, igualmente, para novas formas de criar, ensinar e praticar a medicina^{20,21,22}. Com efeito, é imperativo ao profissional do século XXI coadunar dimensões do saber-fazer humano e tecnológico^{22,23}.

Nas últimas três décadas, o modelo de assistência médica passou por inúmeras mudanças, sobretudo com a incorporação da informática à medicina, com consequências que abrangem desde a produção do conhecimento até a prática clínica²⁴. Os desdobramentos dos novos matizes da compreensão do processo saúde-doença – a abordagem holística do ser humano, o papel do meio ambiente como fator determinante do fenômeno do adoecimento, a evolução do conhecimento científico e a elaboração de protocolos e diretrizes, cada vez mais complexos, para o diagnóstico e o tratamento das moléstias – apontam para o desafio de criar formas de apreendê-los²⁵.

As aplicações das RNA na medicina ganham relevância nesse contexto, na medida em que tem sido investigado seu potencial para a solução de problemas em diversos domínios biomédicos^{26,27}. Esse recurso tecnológico tem alcançado, a cada dia, relevância e aplicabilidade à formação e ao processo avaliativo na escola médica, podendo ser utilizado em inúmeras situações nas quais existe relação entre variáveis – *inputs* – e resultados preditivos – *outputs*⁸. Dentre essas, destacam-se quatro campos básicos: *modulação (simu-*

lação de funções cerebrais e órgãos neurossensoriais); processamento de sinais bioelétricos (filtração e avaliação); diagnóstico (controle e verificação de respostas e interpretação dos resultados); prognóstico (análise retrospectiva de informações armazenadas)^{11,28}.

REDES NEURAIAS ARTIFICIAIS

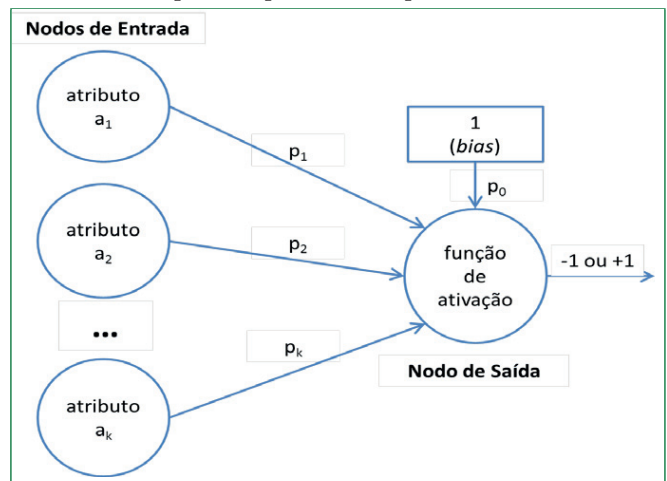
As RNA são sistemas computacionais cuja estrutura lógico-matemática é inspirada na neurofisiologia humana⁶. O processamento de dados se inicia com uma fase de *aprendizagem*, na qual um conjunto de dados – para os quais já se conhecem as respostas – é apresentado, fazendo com que as forças das conexões da rede se alterem de modo a gerar um resultado que seja o mais próximo possível daquele observado nos dados de treinamento. Espera-se, ulteriormente, que a RNA adquira aptidão para generalização, ou seja, a capacidade de fornecer respostas para dados não conhecidos previamente⁸.

O estudo das RNA é uma iniciativa para imitar sistemas neurais biológicos, com o intuito de construir poderosas técnicas de aprendizagem automática²⁹⁻³². De maneira similar ao cérebro do *H. sapiens sapiens*, uma RNA é composta de um conjunto de nodos interconectados por ligações direcionadas. O primeiro método proposto para uma RNA foi chamado de *perceptron*³³. Neste modelo, cuja arquitetura é bastante simples, apenas dois tipos de nodos (neurônios) estão presentes: nodos de entrada e um nodo de saída. Nodos do primeiro tipo representam os atributos dos exemplos de treinamento – bem como das instâncias que se submeterão a posterior classificação pela rede. Já o nodo de saída indica a classificação da instância em questão. Além disso, cada nodo de entrada é conectado ao nodo de saída por uma ligação com peso. Os pesos indicam a força das conexões sinápticas entre os neurônios. Note que o processo ensino-aprendizagem humano consiste, também, na alteração da força de tais conexões, baseada em algum estímulo produzido repetidamente. No *perceptron*, o nodo de saída computa a soma ponderada das entradas, incluindo um termo de influência, ou *bias*, que serve para produzir algum valor no caso em que os pesos são todos nulos. Portanto, é realizada uma combinação linear dos valores fornecidos como entrada. Em seguida, o nodo de saída utiliza a chamada função de ativação, que, neste caso, somente verifica o sinal do valor, para produzir a saída final. Se o valor for negativo, então a saída é -1, caso contrário, a saída é +1, onde esses valores indicam a classe da instância que está sendo analisada. Com efeito, o processo de aprendizagem de um *perceptron* é a adaptação dos valores dos pesos até que seja obtida uma relação acei-

tável entre entrada e saída de acordo com o que é observado nas instâncias de treinamento³³. Uma vez treinada, espera-se que a RNA seja capaz de generalizar o conhecimento sobre os elementos em questão, de modo a classificar – corretamente – exemplos futuros, para os quais ainda não se saiba a classificação correta. A Figura 1 ilustra a arquitetura de um *perceptron*.

FIGURA 1:

O nodo de saída computa a soma: $p_0 + p_1a_1 + p_2a_2 + \dots + p_ka_k$ e verifica se o resultado é negativo ou não. Em seguida, utiliza sua função de ativação simples, que fornece como saída -1 ou +1, respectivamente. O treinamento corresponde a ajustar os pesos de modo a ter as saídas esperadas para os exemplos de treinamento.




Para ser possível modelar relações mais complexas entre valores de entrada e de saída – de modo a, por exemplo, permitir linhas de decisão não necessariamente lineares e ainda mais de uma linha de decisão –, houve uma evolução significativa, a partir do *perceptron*, para uma arquitetura de rede mais completa, chamada de rede neural multicamadas. Neste modelo, a RNA pode conter várias camadas intermediárias, denominadas camadas ocultas, e, ademais, pode utilizar funções de ativação mais complexas, tais como funções tangentes hiperbólicas e funções sigmoidais³². É possível haver, ainda, mais de um nodo de saída. Todas essas características juntas proveem redes mais poderosas e flexíveis.

Outro elemento que dá maior poder às redes neurais é a possibilidade de treinamentos mais rebuscados, como, por exemplo, a aplicação do método de retropropagação (*backpropagation*), no qual o desvio entre saídas observadas e espera-

das é usado numa sofisticada fórmula de correção dos pesos, onde as alterações são aplicadas em direção reversa, ou seja, pesos no nível $d+1$ são modificados antes dos pesos no nível d ³². A Figura 2 mostra uma RNA com uma única camada oculta, por questões de simplificação da imagem.

FIGURA 2:

Exemplo de uma rede neural que utiliza uma camada oculta. Pode haver quantas camadas ocultas forem necessárias e, ainda, mais de uma saída.




Outra característica interessante das RNA é a possibilidade de fornecer, como saída, valores de probabilidade, em vez de valores de classes, como positivo e negativo ou sim e não^{30,31,32}. Por exemplo, para realizar o treinamento de uma RNA que indique – dados os atributos de determinada pessoa, como peso, altura, idade e carga de atividade física – se há ou não risco significativo de problemas cardíacos para um dado indivíduo, as informações e ocorrências desta natureza, de pacientes anteriores, devem ser fornecidas à RNA. No entanto, é muito comum em tais cenários encontrar indivíduos com exatamente as mesmas características, mas com resultados diferentes, ou seja, embora tenham os mesmos valores de atributos, um foi acometido por problemas cardíacos, enquanto o outro não. Em casos como este, faz muito mais sentido fornecer uma tendência sobre a ocorrência de um evento do que informar que este sem dúvida ocorrerá. A ideia é que, ainda que haja diversos indivíduos com características idênticas, mas com resultados distintos, a rede detecte que aque-

les que possuem tais valores de atributos apresentarão menor ou maior chance de apresentar certo quadro – tal como um evento mórbido de origem cardiovascular –, baseando-se, por exemplo, na frequência de determinado resultado nesses indivíduos.

Para fornecer probabilidade como saída, é muito comum o uso de funções sigmóides, na medida em que as mesmas realizam um mapeamento entre os valores obtidos como saída e os correspondentes valores de probabilidade^{30,31,32}. A Figura 3 exibe a função sigmoide. Pode-se perceber na figura que valores negativos são mapeados para probabilidades menores que 0,5, ao passo que valores positivos correspondem a probabilidades superiores ou iguais a 0,5. Isto porque classificadores que exibem probabilidades normalmente realizam o treinamento de modo a utilizar o valor 0,5 para decidir a que classe pertence uma instância. No entanto, embora os valores 0,6 e 0,9, por exemplo, indiquem a mesma classe, o segundo valor provê um grau de confiança muito maior para esta afirmação.

FIGURA 3:

Curva de uma função sigmoide, mapeando valores computados pela rede a valores de probabilidades.



Outra vantagem no uso de probabilidades – em termos das RNA – diz respeito à perspectiva, para o usuário, de analisar vários valores de corte – não só o valor de 0,5 –, podendo verificar as taxas de erro de classificação que o modelo criado possui com relação aos dados de treinamento em questão. Com isto, pode-se estudar a relação custo/benefício de, por exemplo, utilizar um valor de corte maior e, portanto, perder algumas instâncias, mas, por outro lado, ter maior porcentagem de acerto nas instâncias capturadas^{30,31,32}.

QUADRO 2:
Síntese dos principais artigos consultados

Autores	Ano	Contribuições das redes neurais artificiais para o ensino médico	Outras contribuições das redes neurais artificiais para a prática médica
Bergeron et al.	1990	Construção do conhecimento: As RNAs foram utilizadas para a construção de programas educacionais multimídia, gerando melhor compreensão dos conceitos das disciplinas oferecidas.	
Stevens and Lopo	1994	Processo de avaliação: Simulações – baseadas em Imunologia e Infectologia – foram utilizadas para treinar RNAs e auxiliaram a identificação de deficiências específicas no processo ensino-aprendizagem, sobretudo as dificuldades no diagnóstico diferencial.	
Stevens et al.	1996	Processo de avaliação: A utilização de RNAs treinadas para avaliar a solução de problemas complexos – na área de doenças infecciosas – permitiu estudar a dinâmica de aprendizagem de grupo de estudantes de Medicina.	
Stevens and Najafi	2003	Construção do conhecimento: Simulações computacionais foram capazes de proporcionar o manejo de conceitos de Imunologia. Processo de avaliação: As RNAs foram treinadas para julgar a solução do problema, auxiliando a avaliação do desempenho do estudante.	
Olsson et al.	2006		Métodos diagnósticos: A interpretação de alterações no segmento ST do eletrocardiograma, com a utilização de RNAs, demonstrou sensibilidade de 95% e especificidade de 88%, o que pode contribuir para melhor diagnóstico e tratamento de enfermos com síndrome coronariana aguda.
van Heerden et al.	2008	Processo de avaliação: As RNAs foram utilizadas para identificar “preditores” de sucesso acadêmico entre estudantes de Medicina, utilizando 99 variáveis de entrada. Com essa técnica computacional, o desempenho do estudante pode ser previsto com cerca de 100% de precisão.	
Oda et al.	2009		Métodos diagnósticos: As RNAs demonstraram utilidade na detecção de nódulos pulmonares na radiografia de tórax quando comparadas à análise isolada do radiologista.
Adjouadi et al.	2010		Modelos diagnósticos: Estratégia computacional fundamentada em RNAs diagnosticou casos de leucemia linfocítica aguda com sensibilidade de 96,67%.
Mazurovsky et al.	2010	Construção do conhecimento: Um modelo computacional com a função de relacionar as características da imagem com a probabilidade de erro de diagnóstico de câncer de mama feito pelo radiologista em formação, através da análise da mamografia, demonstrou capacidade de prever com precisão o grau de dificuldade de cada caso.	Modelos diagnósticos: Os resultados do estudo demonstram a possibilidade de desenvolver sistemas computacionais de apoio para aprimorar a acurácia no diagnóstico de neoplasias mamárias detectáveis por mamografia.
Dey et al. (a)	2011		Modelos diagnósticos: Casos de carcinoma lobular, neoplasias benignas e carcinoma ductal da mama foram detectados por punção aspirativa por agulha fina (Paaf) e computação dos dados obtidos na citologia, utilizando RNAs.
Dey et al. (b)	2011		Estimativa de prognóstico: Modelos de RNAs foram utilizados, com sucesso, para predição do prognóstico da leucemia mieloide crônica.
Barward et al.	2012		Modelos diagnósticos: Após treinamento adequado, modelos computacionais baseados em RNAs foram capazes de diagnosticar, corretamente, casos de derrame pleural de origem maligna.
Yuan et al.	2012		Estimativa de prognósticos Aplicabilidade das RNAs em prever a resposta à quimioterapia de pacientes com câncer colorretal metastático – com sensibilidade e especificidade de 92,3% para ambas –, considerando o emprego de sete biomarcadores.
Geimer	2013		Métodos diagnósticos: A utilização de algoritmos baseados em RNAs demonstrou maior sensibilidade no diagnóstico de glaucoma em comparação aos oftalmologistas não especialistas nessa enfermidade.

REDES NEURAIAS ARTIFICIAIS: USOS NA EDUCAÇÃO MÉDICA

Inúmeros trabalhos têm demonstrado o papel das RNA na medicina, perpassando desde a formação do profissional até a sua atuação prática (Quadro 2).

RNAs: redes neurais artificiais.

A utilização de novas tecnologias computacionais no ensino médico tem demonstrado inúmeras vantagens no processo de aquisição de habilidades³⁴. Nesta perspectiva, as RNA têm sido cada vez mais empregadas no ensino médico, já que se trata de um modelo computacional extremamente útil para a resolução de problemas clínicos complexos³⁵. Ademais, têm sido descritos efeitos positivos no processo ensino-aprendizagem dos discentes, com aumento da capacidade de armazenamento de informações, de análise sistemática dos dados e de criação de novas abordagens para resolver cada problema apresentado^{35,36}. Com isso, a formação médica pode ser contemplada com maior variedade de conhecimento e formas de aprendizagem, atendendo às necessidades que o presente impõe: uma miríade de habilidades que o profissional médico necessita para atuar^{15,37}.

As RNA também têm sido utilizadas para o processo de avaliação do estudante, quando este é exposto a uma simulação de um caso clínico³⁸. Em outro estudo, foi sugerida a oportunidade de estudar a dinâmica do processo de aprendizagem em diagnóstico clínico e laboratorial, tanto em termos individuais, quanto no âmbito coletivo^{36,38,39}.

Alguns programas computacionais foram elaborados, utilizando a lógica das RNA, e demonstraram capacidade de desenvolver inúmeras habilidades, como proficiência na resolução de questões clínicas associada ao conveniente de serem portáteis, oferecerem interatividade e aprimorarem o aprendizado com recursos gráficos e simulações^{40,41}. Esses programas oferecem uma alternativa às aulas em laboratório, uma vez que permitem simular situações cujas variáveis são difíceis de manipular ou não podem ser alteradas em conjunto com outras⁴⁰. Deve ser destacado, ainda, que os modelos computacionais que simulam o funcionamento neural ganham cada vez mais aplicações na medicina, potencializando a pesquisa científica – auxiliando na ampliação do conhecimento sobre inúmeras condições mórbidas – e o desenvolvimento de novos métodos diagnósticos e de novas abordagens de prognóstico⁴¹⁻⁵¹. Investigações dirigidas a situações nas quais há implicação bioética⁵² – incluindo a perspectiva de tomada de decisão^{53,54} – vêm sendo igualmente desenvolvidas.

Tais observações apontam a necessidade de transformação no currículo médico, com o treinamento dos alunos nessas novas tecnologias²⁴. Com efeito, a incorporação das RNA no ensino da medicina só terá sentido e aplicabilidade com a

transformação pedagógica das instituições de ensino e a partir de uma reflexão sobre o ato de ensinar⁵⁵.

CONSIDERAÇÕES FINAIS

A técnica de RNA representa a cooperação multidisciplinar – envolvendo os campos da neurociência, da matemática, da computação científica e da estatística –, podendo ser aplicada a diversos problemas de diferentes áreas, incluindo a medicina. Sua habilidade em reconhecer padrões é amplamente aplicada em reconhecimento de imagens, análise de espectros, tomada de decisão em problemas complexos – lineares e não lineares –, dentre outros.

As investigações dirigidas às RNA têm possibilitado o desenvolvimento da computação de alto desempenho – com processadores interligados em rede assumindo papel de neurônios –, destacando-se sua elevada capacidade de processamento. Ademais, o avanço na área cognitiva computacional contribui para a construção de máquinas “inteligentes”, hábeis no reconhecimento de padrões, no controle e no processamento de sinais. Não se deve esperar que uma única máquina seja capaz de resolver todos os problemas. Mas cada máquina inteligente poderá adquirir uma aplicação específica – destacando-se, no presente contexto, as aplicações das RNA área médica e no ensino da Medicina.

REFERÊNCIAS

1. Siqueira-Batista R. Conhecimento e saúde: entre ciência e arte. In: Rego S, Palácios M. Comitês de ética em pesquisa: teoria e prática. Rio de Janeiro: Editora Fiocruz; 2012. p. 53-70.
2. Schramm FR. Existem boas razões para se temer a biotecnociência? *Bioethikós* 2010; 4:189-197.
3. Siqueira-Batista R, Maria da Silva L, Medeiros-Souza RR, Pires-do-Prado HJ, Aprigio-da-Silva C, Rôças G, Oliveira AL, Helayël-Neto JA. Nanociência e nanotecnologia como temáticas para discussão de ciência, tecnologia, sociedade e ambiente. *Ciência e Educação (UNESP)* 2010; 16:479-490.
4. Broeders IA. Robotics: The next step? *Best Pract Res Clin Gastroenterol* 2014;28(1):225-32.
5. Siqueira-Batista R. O nascimento da filosofia: uma peça em três atos. *Lugar Comum (UFRJ)* 2011; 33-34:215-225.
6. Nunes WV. Introdução às redes neurais artificiais. In: Esperidião-Antônio V. Neurociências: diálogos e interseções. Rio de Janeiro: Editora Rubio, 2012. p. 1-768.
7. Siqueira-batista R, Esperidião Antonio V, Medeiros-Souza RR, Alves Ferreira R, Gomes AP, Majeski-Colombo M, De Jesus VLB, Oliveira AL, Geller M, Batista RS, Helayël-Neto JA. Neurociências e educação: um tempo de encontro no espaço dos saberes. *Rev Ciências Ideias* 2010; 2(1):1-16.
8. Braga AP, Carvalho APLF, Ludermir TB. *Redes Neurais Artificiais: teoria e aplicações*. Rio de Janeiro: LTC; 2000.

9. Leondes CT. *Neural Network Systems Techniques and Applications*. California: Academic Press; 1998.
10. Patel VL, Shortliffe EH, Stefanelli M, Szolovits P, Berthold MR, Bellazzi R, Abu-Hanna A. The coming of age of artificial intelligence in medicine. *Artif Intelligence Med* 2009; 46(1):5-7.
11. Papik K, Molnar B, Schaefer R, Dombovari Z, Tulassay Z, Feher J. Application of neural networks in medicine: a review. *Med Science Monitor* 1998; 4(3):538-546.
12. Streba CT, Ionescu M, Gheonea DI, Sandulescu L, Ciurea T, Saftoiu A, Vere CC, Rogoveanu I. Contrast-enhanced ultrasonography parameters in neural network diagnosis of liver tumors. *World J Gastroenterol*. 2012;18(32):4427-34.
13. Brasil. Constituição da República Federativa do Brasil. Disponível em: <http://www.senado.gov.br/legislacao/const/con1988/CON1988_05.10.1988/CON1988.pdf> [Acesso em: 28 de fevereiro de 2012].
14. Cotta RMM, Campos AAO, Mendonça ET, Costa GD, Machado JC, Silva LS, Siqueira RL, Leão RT, Reis RS. *Políticas de saúde: desenhos, modelos e paradigmas*. Viçosa: Editora UFV; 2013.
15. Brasil. Resolução CNE/CES Nº 4, de 7 de novembro de 2001. Disponível em: <http://portal.mec.gov.br/cne/arquivos/pdf/CES04.pdf>. [Acesso em: 28 de fevereiro de 2012].
16. Siqueira-Batista R, Gomes AP, Albuquerque VS, Cavalcanti FOL, Cotta RMM. Educação e competências para o SUS: é possível pensar alternativas à(s) lógica(s) do capitalismo tardio? *Ciêns Saúde Coletiva* 2013;18(1):159-170.
17. Freire P. *Pedagogia do oprimido*. 38.ed. São Paulo: Paz e Terra; 2004.
18. Gomes AP. Olhando o sistema de avaliação discente com os óculos da mudança: aprender a ver, aprender a avaliar. In: Moço ETSM, Falcão HBPT, Miranda JFA. *Reflexões sobre as mudanças curriculares na área de saúde: ativando processos*. Rio de Janeiro: Publit; 2007. p. 13-37.
19. Freire P. *Pedagogia da autonomia. Saberes necessários à prática educativa*. São Paulo: Paz e Terra; 2003.
20. Nogueira MI. Trabalho em saúde e trabalho médico: especificidades e convergências. *Rev Bras Educ Med* 2012; 36(3): 414-422.
21. Acharya UR, Yu W. Data Mining Techniques in Medical Informatics. *Open Med Inform J*. 2010; 4: 21-22.
22. Meidani Z, Sadoughi F, Ahmadi M, Maleki MR, Zohoor A, Saddik B. National health information infrastructure model: a milestone for health information management education realignment. *Telemed J E Health*; 18(6):475-83.
23. Ramick DC. Data warehousing in disease management programs. *J Healthc Inf Manag*. 2001; 15(2):99-105.
24. Chen M, Safdar N, Nagy P. Should Medical Schools Incorporate Formal Training in Informatics? *J Digital Imag* 2011; 24(1):1-5.
25. Oden M, Mirabal Y, Epstein M, Richards-Kortum R. Engaging Undergraduates to Solve Global Health Challenges: A New Approach Based on Bioengineering Design. *Ann Biomed Engineering* 2010; 38(9):3031-3041.
26. Al-Shayea QK. Artificial Neural Networks in Medical Diagnosis. *Int J Computer Science Issues* 2011; 8(2):150-154.
27. Suebnukarn S, Haddawy P. A Bayesian approach to generating tutorial hints in a collaborative medical problem-based learning system. *Artif Intell Med*. 2006;38(1):5-24.
28. Oyana TJ, Achenie LE, Heo J. The new and computationally efficient MIL-SOM algorithm: potential benefits for visualization and analysis of a large-scale high-dimensional clinically acquired geographic data. *Comput Math Methods Med*. 2012;2012:683265.
29. Mitchell TM. *Machine Learning*. Singapore: McGraw-Hill; 1997.
30. Baldi P, Brunak S. *Bioinformatics: The machine learning approach*. 2nd edition. Massachusetts: The MIT Press; 2001.
31. Witten IH, Frank E. *Data mining: Practical machine learning tools and techniques*. 2nd edition. San Francisco: Morgan Kaufmann; 2005.
32. Tan PN, Steinbach M, Kumar V. *Introduction to data mining*. Boston: Addison-Wesley; 2006.
33. Rosenblatt F. *The perceptron, a perceiving and recognizing automaton* <Project Para>. Cornell Aeronautical Laboratory report. Buffalo, NY, 1957.
34. Abensur SI, Tamosauskas MRG. Tecnologia da Informação e Comunicação na Formação Docente em Saúde: Relato de Experiência. *Rev Bras Edu Méd* 2011; 35(1):102-107.
35. Stevens RH, Najafi K. Can artificial neural networks provide an “expert’s” view of medical students performances on computer based simulations? *Proceedings of the Annual Symposium on Computer Application in Medical Care* 1992; 179-83.
36. Subbaiah RM1, Dey P, Nijhawan R. Artificial neural network in breast lesions from fine-needle aspiration cytology smear. *Diagn Cytopathol* 2014; 42(3):218-24.
37. Maranhão EA, Gomes AP, Siqueira-Batista R. O que mudou na educação médica a partir das Diretrizes Curriculares Nacionais: sob os olhares do Jano de Duas Faces. In: Streit DS, Barbosa Neto F, Lampert JB, Lemos JMC, Batista NA. *10 anos de Diretrizes Curriculares Nacionais*. Rio de Janeiro: ABEM; 2012. p. 59-91.
38. Stevens RH, Lopo AC. Artificial neural network comparison of expert and novice problem-solving strategies. *Proceedings of the Annual Symposium on Computer Application in Medical Care* 1994; 64-68.

39. Van Heerden B, Aldrich C, du Plessis A. Predicting student performance using artificial neural network analysis. *Med Educ* 2008; 42(5):516-517.
40. Bergeron BP, Morse AN, Greenes RA. A generic neural network-based tutorial supervisor for computer aided instruction? *Proceedings of the Annual Symposium on Computer Application in Medical Care* 1990; 9:435-439.
41. Barwad A, Dey P, Susheilia S. Artificial neural network in diagnosis of metastatic carcinoma in effusion cytology. *Cytometry Part B Clinical Cytometry* 2012; 82(2):107-111.
42. Hu X, Cammann H, Meyer HA, Miller K, Jung K, Stephan C. Artificial neural networks and prostate cancer--tools for diagnosis and management. *Nat Rev Urol* 2013; 10(3):174-8.
43. Dey P, Logasundaram R, Joshi K. Artificial neural network in diagnosis of lobular carcinoma of breast in fine-needle aspiration cytology. *Diagnostic Cytopathology*; 2011.
44. Dey P, Lamba A, Kumari S, Marwaha N (b). Application of an artificial neural network in the prognosis of chronic myeloid leukemia. *Anal Quant Cytol Histol* 2011; 33(6):335-9.
45. Adjouadi M, Ayala M, Cabrerizo M, Zong N, Lizarraga G, Rossman M. Classification of leukemia blood samples using neural networks. *Ann Biomed Engineering* 2010; 38(4):1473-82.
46. Dybowski R, Gant V. *Clinical applications of artificial neural networks*. New York: Cambridge University Press; 2001.
47. Mazurowski MA, Baker JA, Barnhart HX, Tourassi GD. Individualized computer-aided education in mammography based on user modeling: concept and preliminary experiments. *Med Phys* 2010; 37(3):1152-60.
48. Geimer SA. Glaucoma diagnostics. *Acta Ophthalmol* 2013; 91(thesis1):1-32.
49. Stevens RH, Lopo AC, Wang P. Artificial neural networks can distinguish novice and expert strategies during complex problem solving. *J Am Med Informatics Assoc* 1996; 3(2):131-138.
50. Yuan Y, Tan CW, Shen H, Yu JK, Fang XF, Jiang WZ, Zheng S. Identification of the biomarkers for the prediction of efficacy in first-line chemotherapy of metastatic colorectal cancer patients using SELDI-TOF-MS and artificial neural networks. *Hepatogastroenterology* 2012; 5 (120): 2461-5.
51. Oda S, Awai K, Suzuki K, Yanaga Y, Funama Y, MacMahon H, Yamashita Y. Performance of radiologists in detection of small pulmonary nodules on chest radiographs: effect of rib suppression with a massive-training artificial neural network. *AJR Am J Roentgenol* 2009; 193(5):W397-402.
52. Olsson SE, Ohlsson M, Ohlin H, Dzaferagic S, Nilsson ML, Sandkull P, Edenbrandt L. Decision support for the initial triage of patients with acute coronary syndromes. *Clin Physiol Funct Imaging* 2006; 26(3):151-6.
53. Kim SH, Lee JM, Kim JH, Kim KG, Han JK, Lee KH, Park SH, Yi NJ, Suh KS, An SK, Kim YJ, Son KR, Lee HS, Choi BI. Appropriateness of a donor liver with respect to macrosteatosis: application of artificial neural networks to US images--initial experience. *Radiology* 2005; 234(3):793-803.
54. Siqueira-Batista R, Cerqueira FR. Computational support for decision making in clinical bioethics. In: *X Congresso Brasileiro de Bioética*, 2013, Florianópolis. *Rev Bras Bioética* 2013; 9(supl.): 202-203.
55. Siqueira-Batista R, Schramm FR. Bioética e neurociências: variações sobre o tema dos paradoxos da autonomia. In: *Esperidião-Antônio V. Neurociências: diálogos e interseções*. Rio de Janeiro: Editora Rubio, 2012, p. 473-487.
56. Barnett GO. Information technology and medical education. *J Am Med Informatics Assoc* 1995; 2(5):285-91.

CONTRIBUIÇÃO DOS AUTORES

Rodrigo Siqueira-Batista desenhou com Fabio Ribeiro Cerqueira a estrutura do presente artigo. Ambos contribuíram igualmente neste trabalho. Na sequência, Rodrigo Roger Vitorino elaborou – sob a orientação de ambos – a primeira versão. Andréia Patrícia Gomes, Alcione de Paiva Oliveira, Ricardo dos Santos Ferreira, Vanderson Esperidião-Antonio e Luiz Alberto Santana procederam à revisão final do texto.

CONFLITO DE INTERESSES

Os autores declaram não haver conflito de interesses.

ENDEREÇO PARA CORRESPONDÊNCIA

Rodrigo Siqueira-Batista
Universidade Federal de Viçosa
Campus de Viçosa
Departamento de Medicina e Enfermagem
Avenida Peter Henry Rolfs, s/n
Campus Universitário
Viçosa – MG
CEP: 36570-900
E-mail: rsbatista@ufv.br

Fábio Ribeiro Cerqueira
Universidade Federal de Viçosa
Campus de Viçosa
Departamento de Informática
Avenida Peter Henry Rolfs, s/n
Campus Universitário
Viçosa – MG
CEP: 36570-900
E-mail: frcerqueira@gmail.com