

Utilização de redes neurais artificiais para a determinação do número de refeições diárias de um restaurante universitário

Use of artificial neural networks to determine the daily number of meals served by a university cafeteria

José Celso ROCHA¹
Felipe Delestro MATOS¹
Fernando FREI¹

RESUMO

Objetivo

Construir uma rede neural artificial para auxiliar os gestores de restaurantes universitários na previsão de refeições diárias.

Métodos

O estudo foi desenvolvido a partir do levantamento de oito variáveis que influenciam o número de refeições diárias servidas no restaurante universitário. Utiliza-se o algoritmo de treinamento *Backpropagation*. Os resultados por meio da rede são comparados com os da série estudada e com resultados da estimativa por média aritmética simples.

Resultados

A rede proposta acompanha as inúmeras alterações que ocorrem no número de refeições diárias do restaurante universitário. Em 73% dos dias analisados, o método das redes neurais artificiais apresenta uma taxa de acerto maior do que o método da média aritmética simples.

Conclusão

A rede neural artificial mostrou-se mais adequada para a previsão do número de refeições do que a metodologia de média simples ou quando a decisão do número de refeições é feita de forma subjetiva, sem critérios científicos.

Termos de indexação: Desperdícios de alimentos. Redes neurais artificiais. Serviços de alimentação.

¹ Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências e Letras, Curso de Engenharia Biotecnológica, Departamento de Ciências Biológicas. Av. Dom Antônio, 2100, 19806-900, Assis, SP, Brasil. Correspondência para/Correspondence to: J.C. ROCHA. E-mail: <jcelso@assis.unesp.br>.

ABSTRACT**Objective**

This study aimed to build an artificial neural network to help the managers of university cafeterias to predict the number of daily meals.

Methods

This study was based on a survey of eight variables that influence the number of daily meals served by a university cafeteria. Backpropagation training algorithm was used and the results obtained by the network are compared with results of the studied series and the results estimated by simple arithmetic average.

Results

The proposed network follows the numerous changes that occur in the number of daily meals of the university cafeteria. In 73% of the analyzed days, the artificial neural networks method presented a greater success rate than the simple arithmetic average method.

Conclusion

Artificial neural network predicted the number of meals better than the simple average method or than decisions made subjectively.

Indexing terms: Food wasterfoulness. Artificial neural networks. Food services.

INTRODUÇÃO

As Unidades de Alimentação e Nutrição (UAN) são espaços destinados a oferecer alimentação adequada às necessidades nutricionais da clientela¹. O desperdício de alimentos nas UAN é uma das preocupações de administradores e de nutricionistas e tem causas econômicas, culturais e tecnológicas. Para que o desperdício possa ser minimizado ou mesmo eliminado, já que não existe um percentual ideal de sobras², deve-se buscar métodos para planejar a produção diária de tal forma que não existam excessos na produção³.

No que concerne especificamente às UAN universitárias, tanto o desperdício quanto a elevação dos preços dos alimentos têm um impacto direto no valor das compras e é uma das maiores preocupações dos gestores desse tipo de UAN, visto que o maior aproveitamento dos alimentos evita repasses financeiros frequentes aos clientes, nesse caso estudantes³.

A Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP) tem 32 unidades universitárias distribuídas pelo estado de São Paulo, entre as quais o *campus* da Faculdade de Ciências e Letras de Assis (FCL/Assis), cidade situada no oeste do estado, com cinco cursos de graduação

e cinco cursos de pós-graduação, totalizando 2 175 alunos matriculados nos diversos cursos nos períodos matutino, vespertino e noturno, sendo a sua maioria no período vespertino e noturno. O número médio diário de refeições servidas no almoço no período de 2008/2009 foi de 366 refeições ao dia. No entanto, a amplitude de atendimento varia entre 100 e 500 refeições.

Essa situação representa um desafio para a equipe que gerencia o restaurante, que necessita planejar diariamente o número de refeições. No entanto, por se tratar de um Restaurante Universitário (RU), em que o custo é fator primordial, não há qualquer sistema que permita a previsão de refeições a serem servidas, sendo elas determinadas pela intuição e pela experiência da nutricionista responsável. Dessa forma, as estimativas para o número de refeições podem ocasionar desde sobras excessivas até a sobrecarga da equipe no preparo urgente de refeições, o que pode comprometer sua qualidade. Assim, um sistema computacional que possa prever com maior precisão o número de refeições a serem servidas no RU seria de grande apoio para a equipe de gestores.

Entre as diversas metodologias que podem ser empregadas para previsão do número de

refeições em restaurantes universitários, destacam-se as Redes Neurais Artificiais (RNA).

Inspiradas no funcionamento do neurônio biológico típico, as RNA são técnicas computacionais que utilizam modelos matemáticos para a classificação de padrões, simulação de atividades humanas, agrupamento de dados, previsões temporais, entre outras aplicações^{4,5}. Uma importante característica das RNA é a habilidade de aprender a partir de casos reais conhecidos, o que proporciona o aprimoramento de seu desempenho. Esse aprendizado é feito por um processo iterativo e ocorre quando a RNA atinge uma solução generalizada para uma classe de problemas previamente apresentados a ela⁶.

A capacidade das RNA de aprender com exemplos reais e de reconhecer situações semelhantes àquelas utilizadas no seu aprendizado/treinamento despertou o interesse de pesquisadores em várias áreas do conhecimento, como no processamento e na interpretação de imagens⁷⁻¹⁰, automação e controle¹¹⁻¹³, séries temporais^{14,15}, tratamento de efluentes¹⁶, auxílio a diagnóstico médico¹⁷⁻²⁰, nutrição e alimentos²¹⁻²⁶, entre muitos outros.

O presente estudo tem como objetivo implementar um sistema de RNA que auxilie os gestores do RU na previsão diária de refeições.

MÉTODOS

O restaurante universitário, alvo da pesquisa, está alocado na FCL/Assis/Unesp. Os dados para a composição da amostra do número de refeições diárias fornecidos pela administração do restaurante universitário compreendem o período de maio de 2008 a dezembro de 2009, perfazendo um total de 254 dias. No presente estudo foi utilizada a metodologia de redes neurais artificiais multicamadas, tendo como método de treinamento o *Backpropagation*.

Para atender aos requisitos da metodologia de RNA, as variáveis preditivas a serem estudadas foram selecionadas pelos pesquisadores

e nutricionista responsável pelo RU, e são apresentadas a seguir: nível de aceitação das refeições; média dos últimos 30 dias; dia da semana; número de refeições do dia anterior; mês; existência de feriado no dia anterior; média dos últimos 5 dias e existência de feriado no dia posterior.

Para obtenção da variável "nível de aceitação das refeições", foi desenvolvido um questionário que foi aplicado a 350 usuários para avaliar a aceitação dos pratos principais de todos os cardápios servidos pelo RU. Os usuários do restaurante universitário foram informados sobre os objetivos da pesquisa, tendo sido voluntária a participação. Foi esclarecido que as informações obtidas poderiam ser divulgadas em meios científicos e as análises seriam realizadas em conjunto com as de outros voluntários, não sendo divulgada a identificação de nenhum participante, e que eventuais dúvidas poderiam ser esclarecidas em qualquer etapa do estudo. Analisando a preferência dos indivíduos pelos pratos principais dos cardápios do restaurante universitário, foram constatados os seguintes níveis de aceitação: filé de frango à milanesa (0,9212), espeto de frango à milanesa (0,9147), estrogonofe (0,9016), ron-delli (0,8849), frango grelhado (0,8694), filé de frango à pizzaiolo (0,8550), bife à milanesa (0,8505), fricassê (0,8002), bife à pizzaiolo (0,7935), bife grelhado (0,7922), rolê de frango (0,7793), frango assado (0,7785), frango xadrez (0,7710), carne assada (0,7698), pernil acebolado (0,7608), bife acebolado (0,7497), bife à role (0,7327), peixe (0,7239), carne com batatas (0,6993), frango com legumes (0,6905), frango ao molho (0,6587), carne com legumes (0,6565), kibe assado (0,6541), almôndegas (0,6171), carne de panela (0,5724), picadinho de carne com legumes (0,5492), steak (0,5295), picadinho misto (0,5266), carne moída (0,5261) e hambúrguer (0,5046).

As demais variáveis foram disponibilizadas pelos gestores do RU e pela seção de graduação da unidade para o período de pesquisa em foco.

A RNA utilizada para este estudo é denominada de rede multicamadas, tendo como méto-

do de treinamento o *Backpropagation*. As redes neurais multicamadas são assim chamadas por serem formadas por camadas de neurônios interconectados entre si (Figura 1). O método de treinamento escolhido proporciona uma maior eficiência na manipulação das informações e na otimização do processo^{6,27}.

Por neurônio, entende-se uma função matemática que processa as informações provenientes das variáveis preditivas com suas respectivas ponderações.

O método *backpropagation* consiste em duas fases, conhecidas como *feedforward* e *feedbackward*²⁷. Na fase *feedforward*, as variáveis preditivas são processadas pela RNA, que apresenta como resposta o número de refeições preditas pela própria rede à qual é, posteriormente, comparada, com o respectivo valor real. Caso a diferença entre o valor predito e o real for maior que determinado erro, a rede utiliza a fase *feedbackward*, que consiste no recálculo do processo mediante a alteração da ponderação para cada variável e cada neurônio. Esse procedimento, chamado treinamento, é feito até que se obtenha um número de refeições para um determinado dia, dentro de um erro previamente estabelecido.

No presente estudo, a RNA teve sua estrutura formada por duas camadas, sendo a primeira com 20 neurônios e a camada de saída com um neurônio (Figura 1), que deve fornecer o número de refeições a serem servidas. O número de neurônios e de camadas ideal foi definido a partir de estudos prévios com estruturas diversas.

Para obtenção da melhor resposta foi realizado o treinamento da RNA por meio do software Matlab®²⁸. Após o treinamento, a rede neural estará apta a ser utilizada na projeção futura do número de refeições a serem oferecidas.

De forma a facilitar a utilização da RNA por parte dos gestores do RU, foi desenvolvido um programa que pode ser instalado em qualquer computador, de maneira a permitir uma fácil obtenção do número de refeições diárias mediante a inserção dos valores das oito variáveis de entrada (número de refeições, dias da semana, mês etc.) (Figura 2).

Com o objetivo de comparar a RNA com outro processo usual de estimativa, foi utilizada a metodologia da média aritmética simples, baseada em séries estatísticas que determinam o número de refeições para cada dia da semana.

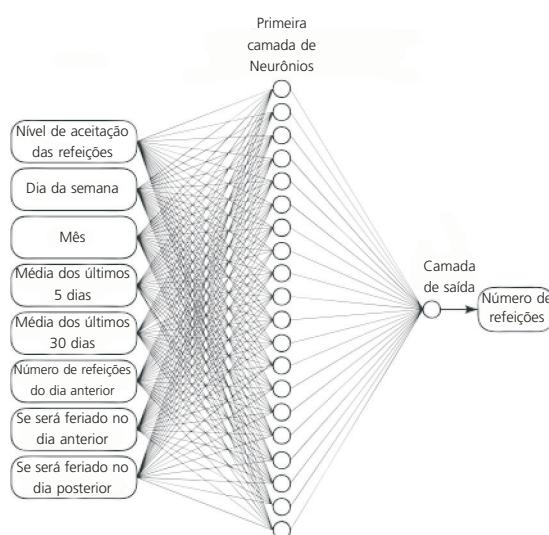


Figura 1. Arquitetura da rede neural artificial.

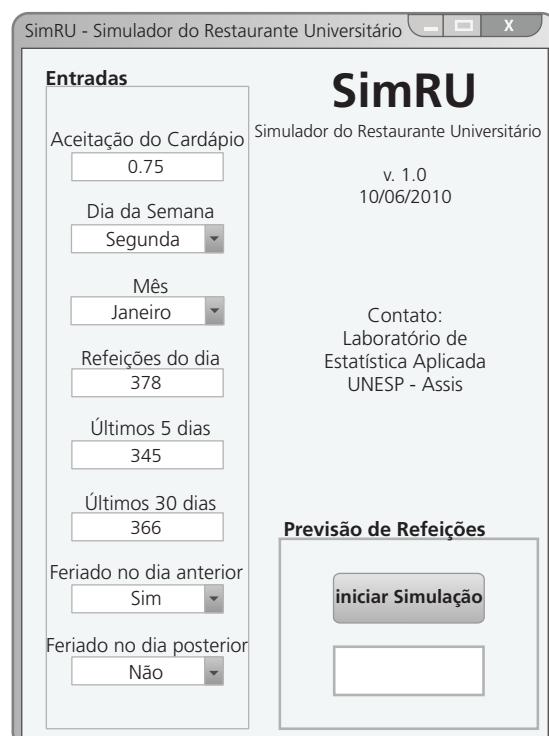


Figura 2. Programa computacional (simulador) para obtenção do número de refeições diárias.

RESULTADOS

O conjunto de métodos utilizados para a determinação do número de refeições diárias a serem servidas no RU permite observar se os critérios adotados na construção da RNA para as variáveis de entrada, estrutura da rede e treinamento proposto estão adequados.

A Figura 3 apresenta a comparação dos resultados simulados pela RNA em relação aos valores reais fornecidos pelos gestores do RU no decorrer do tempo. Pode-se observar também que os resultados simulados pela RNA acompanham satisfatoriamente as variações reais do número de refeições.

A Figura 4 mostra capacidade preditiva da RNA, indicada pela preponderância dos valores acima de zero.

DISCUSSÃO

Por se tratar de um restaurante universitário, muitas vezes a otimização do processo é deixada de lado por ser considerada onerosa e trazer custos adicionais às refeições, o que nunca é bem visto pelos usuários. No caso em questão,

a responsabilidade de definir o número de refeições a serem servidas em determinado dia cabe à nutricionista responsável pelo RU, que o faz de forma subjetiva.

Uma solução computacional para estimar o número de refeições diárias do RU, com precisão acurada, apresenta alta complexidade em função das diversas variáveis componentes do processo. Para o estudo em pauta, o erro geral obtido pela metodologia da RNA foi de 9,5%. Para outras áreas, o percentual de erro quando da utilização das RNA é variável, no entanto elas apresentam, em geral, melhores resultados em comparação a outros métodos²⁹.

No Brasil, a aplicação de RNA para estimativa do número de refeições nas UAN ainda é incipiente e, portanto, carece de estudos comparativos. Para redução de erro, pode-se incluir variáveis que se mostraram importantes no processo mas que ficaram ausentes deste estudo por serem de difícil acesso. Outros trabalhos eliminam situações atípicas em que as RNA apresentam dificuldades em acompanhar os valores reais, ou ainda situações de sazonalidade e ciclos³⁰. Entre as situações atípicas, para o presente estudo, destaca-se a variável denominada “eventos”, que consiste nos dias em que ocorrem congressos, se-

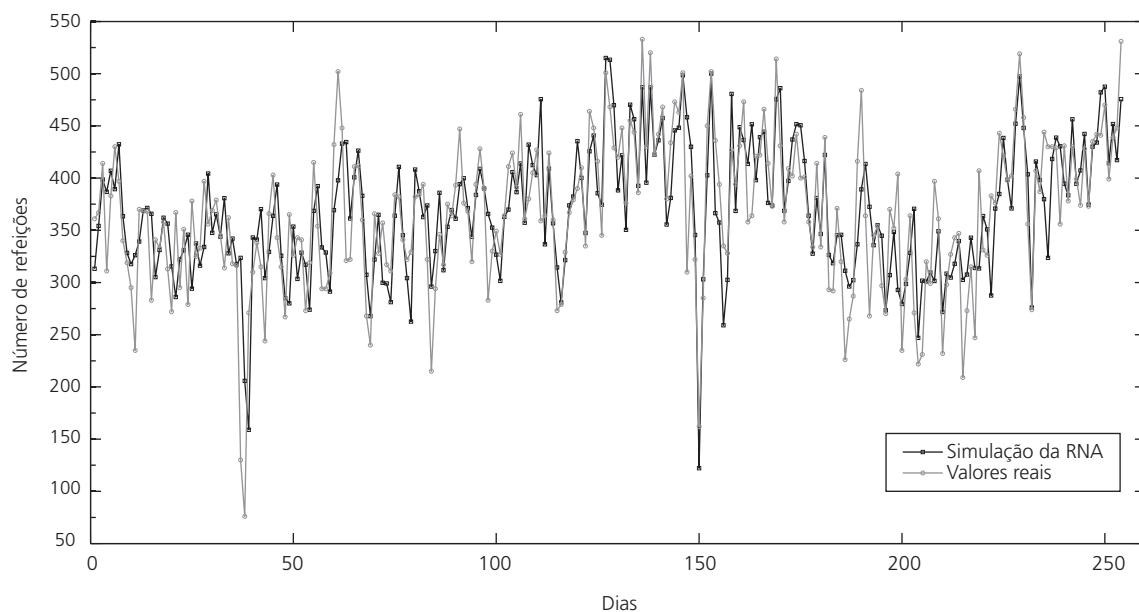


Figura 3. Desempenho da rede neural artificial em comparação ao número de refeições reais.

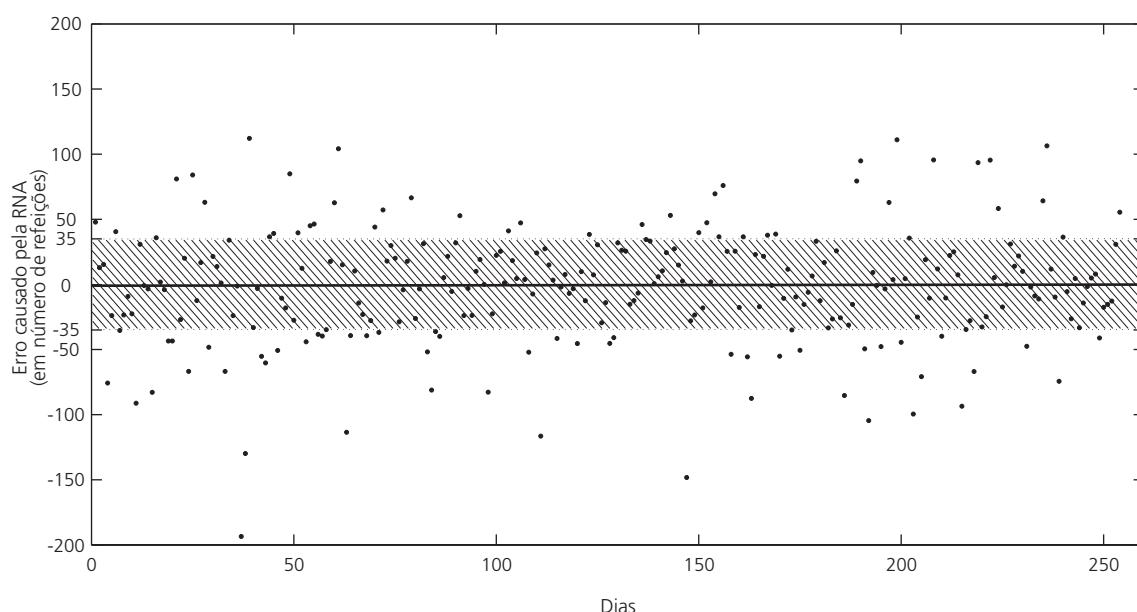


Figura 4. Erro do número de refeições após treinamento da rede neural artificial.

minários, e outros eventos que ocasionam um fluxo de indivíduos fora do padrão atendido pelo RU. Essa situação pode ser verificada na Figura 3, quando se observa o 62º dia, em que o número de refeições foi igual a 500 e a estimativa fornecida pela RNA foi de 400. Por outro lado, a RNA apresenta alta precisão na maioria dos dias. Pode-se observar também que a RNA acompanha as várias oscilações no número de refeições diárias servidas pelo RU, característica também observada nos estudos realizados por Calôba *et al.*³⁰.

De forma geral, a dispersão dos erros obtidos pela RNA pode ser considerada altamente aceitável, uma vez que, em sua maioria (62,2%), eles encontram-se na faixa de 35 refeições, para mais ou para menos, em um universo médio de 366 refeições ao dia, que pode inclusive chegar a 500 refeições diárias. Na faixa de erros mencionada, 24,0% deles são referentes à estimativa do número de refeições abaixo dos valores reais (de 5 a 35 refeições), o que poderia trazer dificuldade no pleno atendimento dos usuários. Por outro lado, a RNA apresenta 25,0% de erro na estimativa acima dos valores reais (de 5 a 35 refeições), o que ocasionaria total atendimento aos usuários, mas com um pequeno desperdício de material e de mão de obra. Os restantes 13,0%

de erro encontram-se próximos a zero, situação ideal (Figura 4).

Em relação à tomada de decisão para o número de refeições a serem servidas no RU, a técnica das RNA se mostra mais eficaz em comparação com o método da média simples, como se pode observar na Figura 5, que apresenta a diferença entre o erro causado pela média simples e o erro causado pela RNA: os valores positivos informam o quanto a média simples errou a mais do que a RNA, e os valores negativos o quanto a RNA errou a mais que o método da média simples.

Do total de dias analisados, verifica-se que em 73% (187 dias), o método de média simples propiciou um maior erro em relação à RNA, que por sua vez ocasionou um erro maior nos 23% (69 dias) restantes. Em se tratando de menor desperdício, observa-se que a RNA apresenta erros maiores que 50 refeições em 13 dias, enquanto o método da média simples apresenta erros maiores que 50 refeições em 58 dias (Figura 5). Dessa forma, considerando a complexidade e não linearidade do problema em estudo, pode-se verificar que há uma melhora considerável quando se compara o sistema de RNA com uma abordagem de média aritmética simples.

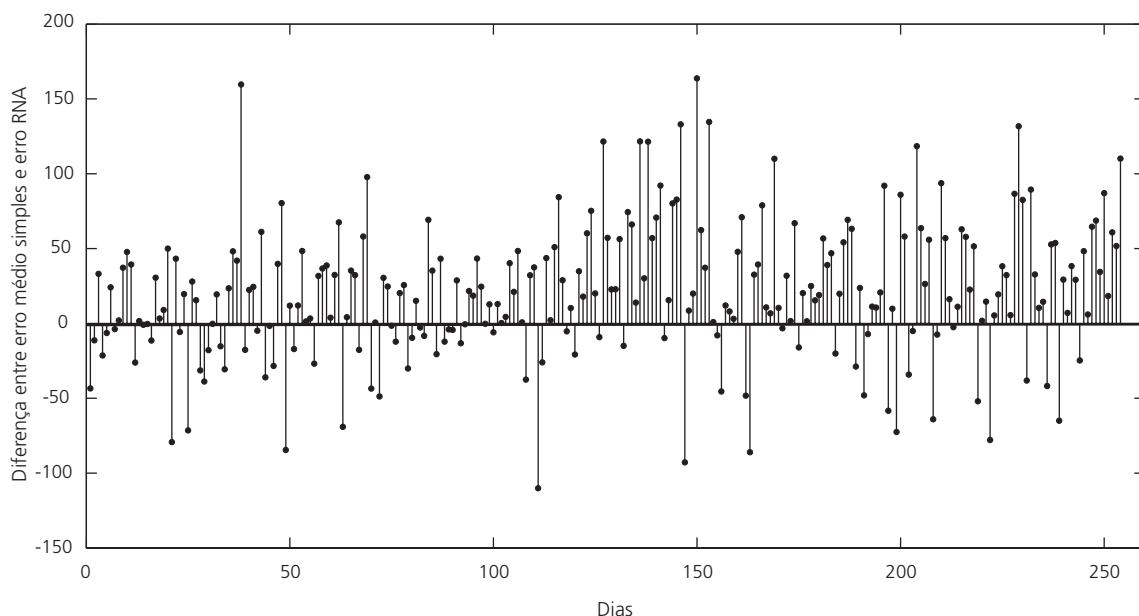


Figura 5. Diferença entre o erro causado pela média simples e o erro causado pela rede neural artificial.

CONCLUSÃO

A definição do número de refeições a serem servidas no restaurante universitário pode ser realizada por meio de uma rede neural artificial em substituição a uma forma subjetiva, pouco adequada, ou em substituição ao método de média aritmética simples.

Havendo um maior comprometimento dos diversos setores do *campus* universitário, no sentido de prever seus eventos e número de participantes durante o período de aula, novas variáveis de entrada poderiam ser criadas para a rede neural artificial, de modo que taxas ainda menores de erro poderiam ser obtidas, possibilitando melhores condições para a tomada de decisões pelos gestores do restaurante universitário.

O sistema computacional desenvolvido pode, inclusive, ser adaptado para funcionar em outros tipos de restaurantes, levando em consideração suas particularidades. Essa flexibilidade é inerente às redes neurais artificiais, sendo necessária apenas uma base de dados referente à nova situação, de modo que seja possível realizar novo treinamento. Caso a nova situação se caracterize por condições mais específicas, outras

variáveis de entrada podem ser adicionadas à rede.

Pelo exposto, as redes neurais artificiais podem contribuir para o melhor funcionamento dos restaurantes, de forma a reduzir custos, desperdícios alimentares e mão de obra.

COLABORADORES

Todos os autores participaram de todas as fases do artigo.

REFERÊNCIAS

1. Antunes MA, Andrade NJ, Silva CAB, Azeredo RMC, Lopes FA. Sistema multimídia de apoio à decisão em procedimentos de higiene para unidades de alimentação e nutrição. Rev Nutr. 2006; 19(1); 93-101. doi: 10.1590/S1415-52732006000100010.
2. Abreu ES, Spinelli MGN, Zanardi AMP. Gestão de unidades de alimentação e nutrição: um modo de fazer. 2^a ed. São Paulo: Metha; 2007.
3. Ricarte MPR, Moura Fé MAB, Santos IHVS, Lopes AKM. Avaliação do desperdício de alimentos em uma unidade de alimentação e nutrição institucional em Fortaleza-CE. Saber Científico. 2008; 1(1):158-75.

4. Zuben FJV. Uma caricatura funcional de redes neurais artificiais. *Rev SBRN*. 2003; 1(2):66-76.
5. Kovács ZL. Redes neurais artificiais: fundamentos e aplicações. 3ª ed. São Paulo: Livraria da Física Editora; 2002.
6. Braga AP, Carvalho APLF, Ludemir TB. Redes neurais artificiais: teoria e aplicações. 2ª ed. Rio de Janeiro: Livro Técnico e Científico; 2007.
7. Chagas CS, Vieira CAO, Fernandes Filho EI, Waldir Júnior C. Utilização de redes neurais artificiais na classificação de níveis de degradação de pastagens. *Rev Bras Eng Agric Ambient*. 2008; 13(3):319-27.
8. Pérez A, Mas JF, Velázquez A, Vázquez L. Modeling vegetation diversity types in Mexico based upon topographic features. *Interciência*. 2008; 33(2):88-95.
9. Gleriani JM. Redes neurais artificiais para classificação espectro-temporal de culturas agrícolas [doutorado]. São José dos Campos: INPE; 2004.
10. Cruz NC, Galo MLBT. Mapeamento das infestações por plantas aquáticas em reservatórios utilizando imagens multiescala e redes neurais artificiais. *RBC*. 2005; 57(2):103-12.
11. Arruda EF, Carneiro AAFM, Coury DV, Delmont OF, Souza SA, Oleskovicz M. Estudo comparativo de ferramentas modernas de análise aplicadas à qualidade da energia elétrica. *Rev Contr Autom*. 2006; 17(3):331-41.
12. Coury DV, Segatto EC. Inteligência aplicada à proteção de transformadores de potência. *Rev SBRN*. 2006; 4(2):70-8.
13. Chávez G, Muniz C, Figueiredo K, Pacheco M, Vellasco M. Indicação de suspeitos de irregularidades em instalações elétricas de baixa tensão. *Rev SBRN*. 2008; 6(1):16-28
14. Zanetti SS, Sousa EF, Carvalho DF, Bernardo S. Estimação da evapotranspiração de referência no estado do Rio de Janeiro usando redes neurais artificiais. *Rev Bras Eng Agríc Ambient*. 2007; 12(2):174-80.
15. Moreira MC, Pruski FF, Oliveira TECO, Pinto FAC, Silva DD. Neterosividade MG: erosividade da chuva em Minas Gerais. *Rev Bras Cienc Solo*. 2008; 32: 1349-53.
16. Silveira DD. Modelo para seleção de sistemas de tratamento de efluentes de indústrias de carnes [doutorado]. Florianópolis: Universidade Federal de Santa Catarina; 1999.
17. Santos WP, Souza RE, Silva AFD, Santos Filho PB. Avaliação da doença de Alzheimer pela análise multiespectral de imagens DW-MR por redes RBF como alternativa aos mapas ADC. *Rev SBRN*. 2006; 4(1):41-53.
18. Argoud FIM, Azevedo FM. Sistema de detecção automática de paroxismos epileptogênicos em sinais de eletroencefalograma. *Rev Contr Autom*. 2004; 15(4):467-75.
19. Gandia CP, Facchinetti A, Sparacino G, Cobelli C, Gómez EJ, Rigia MMD, et al. Artificial neural network algorithm for online glucose prediction from continuous glucose monitoring. *Diabetes Technol Ther*. 2010; 12(1):81-8
20. Goulear DA, Tacla MA, Marback PMF, Solé D, Paranhos Junior A, Perez HB, et al. Redes neurais artificiais aplicadas no estudo de questionário de varredura para conjuntivite alérgica em escolares. *Arq Bras Oftalmol*. 2006; 69(5):707-13.
21. Sousa EA, Teixeira LCV, Mello MRPA, Torres EAES, Moita Neto JM. Aplicação de redes neurais para avaliação do teor de carne mecanicamente separada em salsicha de frango. *Ciênc Tecol Aliment*. 2003; 23(3):307-11.
22. Gabuti L, Burnier M, Mombelli G, Malé F, Pelledrini L, Marone C. Usefulness of artificial networks to predict follow-up dietary protein intake in hemodialysis patients. *Kidney Int*. 2004; 66:399-407. doi: 10.1111/j.1523-1755.2004.00744.x.
23. Argyri AA, Panagou EZ, Tarantilis PA, Polysiou M, Nyhas GJE. Rapid qualitative and quantitative detection of beef fillets spoilage based on Fourier transform infrared spectroscopy data and artificial neural networks. *Sens Actuators B*. 2010; 145: 146-54.
24. Salle CTP, Guahyba AS, Wald VB, Silva AB, Salle FO, Fallavena LCB. Uso de redes neurais artificiais para estimar parâmetros de produção de galinhas reprodutoras pesadas em recria. *Rev Bras Cienc*. 2001; 3(3):257-64.
25. Khatchatourian O, Padilha FRR. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. *Eng Agric Jaboticabal*. 2008; 28(4):759-69.
26. Vale CM, Zambiasi RC. Previsão de estabilidade de óleos vegetais através da rede de inteligência artificial. *Ciênc Tecnol*. 2000; 20(3):342-8.
27. Haykin S. Redes neurais: princípios e prática. 2ª ed. Porto Alegre: Bookman; 2001
28. The MathWorks [Internet]. Neural Network ToolboxTM 7 User's Guide 1992/2010 [cited 2010 Sept 23]. Available from: <http://www.mathworks.com/help/pdf_doc/nnet/nnet.pdf>.
29. Oliveira ACS, Souza AA, Lacerda WS, Gonçalves LR. Aplicação de redes neurais artificiais na previsão da produção de álcool. *Ciênc Agrotec*. 2010; 34(2): 279-84.
30. Calôba GM, Calôba LP, Saliby E. Cooperação entre redes neurais artificiais e técnicas 'clássicas' para previsão de demanda de uma série de vendas de cervejaria na Austrália. *Pesq Oper*. 2002; 22(3):345-58.

Recebido em: 8/10/2010
 Versão final reapresentada em: 10/5/2011
 Aprovado em: 21/7/2011