



## Redes Neurais Artificiais “*Backpropagation*” para a Recuperação da Qualidade Química de Solos Degradados <sup>(1)</sup>.

Alfredo Bonini Neto<sup>(2)</sup>; Carolina dos Santos Batista Bonini<sup>(3)</sup>; Beatriz Santos Bisi<sup>(4)</sup> e Maria Carolina Nakatani<sup>(4)</sup>

<sup>(1)</sup> Trabalho executado com recursos da UNESP – campus de Tupã.

<sup>(2)</sup> Professor Assistente Doutor - Engenharia de Biossistemas - UNESP – Campus de Tupã - São Paulo, bonini@tupa.unesp.br; <sup>(3)</sup> Professora Assistente Doutora – Engenharia Agrônômica, UNESP – Campus de Dracena - São Paulo; <sup>(4)</sup> Estudante de Graduação do curso de Engenharia de Biossistemas - UNESP – Campus de Tupã - São Paulo

**RESUMO:** As Redes Neurais Artificiais (RNA) são modelos computacionais que se assemelham aos neurônios biológicos, capaz de realizar aprendizado e manipular informações recebidas. Este trabalho apresenta uma técnica classificadora de níveis de solos degradados de acordo com seus atributos químicos via RNA. Com os resultados obtidos, observou-se que os solos analisados apresentam fertilidade aparente muito baixa indicando sua degradação e também mostrou que quanto mais profundo o solo, menor é sua fertilidade aparente, o que é esperado.

**Termos de indexação:** Neurônio artificial, Classificação de solos, Retropropagação, Propriedades químicas.

### INTRODUÇÃO

As redes neurais artificiais (RNA) são sistemas computacionais adaptativos inspirados nas características de processamento de informação semelhante ao neurônio biológico de organismos inteligentes. Constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Essas redes permitem produzir saídas adequadas para entradas que não estavam presentes durante o treinamento.

Esses sistemas se assemelham ao cérebro humano de forma que o conhecimento de ambos são adquiridos a partir de seu ambiente através de um processo de aprendizagem e pela força de conexão entre os neurônios, no cérebro, e as redes, nos sistemas, denominados pesos sinápticos, os quais são utilizados para armazenar o conhecimento adquirido.

Nos últimos anos, publicações de trabalhos envolvendo redes neurais artificiais (RNA) têm crescido gradativamente no Brasil. SOARES et al (2014), objetivaram utilização de redes neurais artificiais para predição da produtividade da cultura do feijão, BUCENE & RODRIGUES (2004), utilizaram as redes neurais artificiais para avaliação de produtividade do solo, visando classificação de terras para irrigação e CURI et al (2014), utilizaram redes neurais artificiais na predição da vazão ideal de exaustores em aviários de frango de corte com

diferentes tipologias.

E no exterior tem-se publicações de BEUCHERA et al (2015), que utilizaram as redes neurais artificiais para mapeamento de solo e caracterização das propriedades do solo relevantes para o planejamento ambiental; ANAGU et al (2009), utilizaram as redes neurais artificiais para desenvolver modelos de sorção (conjunto dos fenômenos de absorção, adsorção e dessorção) em função de propriedades básicas do solo e SILVEIRA et al (2013), manipularam as redes neurais artificiais do tipo multicamadas com o objetivo de prever solos de acordo com seus atributos.

Esses estudos devem-se ao grande poder de aplicações destas metodologias em diversas áreas. As redes neurais artificiais são capazes de extrair informações não apresentadas de forma explícitas através de exemplos; são adequadas para a análise de sistemas com incertezas, sendo usadas como alternativas aos métodos estatísticos.

Com isso, nesta primeira parte do trabalho é apresentado o processo de funcionamento da rede neural artificial, o algoritmo Retropropagação (*backpropagation*), o qual consiste em multicamadas não-recorrentes, com treinamento supervisionado.

Este trabalho tem por objetivo analisar dados de solos degradados via RNA, levando em conta os tratamentos utilizados, a profundidade analisada e as propriedades químicas do solo.

### MATERIAL E MÉTODOS

O trabalho foi realizado em Selvíria, MS. A região apresenta médias de precipitação anual de 1370 mm, temperatura de 23,5 °C e umidade relativa do ar entre 70 e 80%. O solo original da área de estudo foi classificado Latossolo Vermelho distrófico (EMBRAPA, 2013). Da área em estudo, foram retirados 8,6 m do perfil do solo original, para o uso na construção da Usina Hidrelétrica de Ilha Solteira, ficando exposto o subsolo da área em estudo, desde 1969. Maiores detalhes da área experimental (histórico) podem ser encontrados em Bonini (2012).

O experimento para recuperação da qualidade química consistiu em 9 tratamentos de recuperação, sendo eles: calcário+gesso+guandu, calcário+gesso

+mucuna-preta, calcário+guandu, calcário+ mucuna-preta, guandu, vegetação nativa do cerrado, mucuna-preta, solo exposto e solo mobilizado.

A fertilidade do solo pode ser classificada a partir de análises químicas do mesmo, o qual permite análises de níveis de degradação do composto. Os atributos químicos utilizados para classificação do solo do presente trabalho foram: CTC, capacidade de troca catiônica; V%, saturação de bases; pH que indica a acidez do solo; e os níveis de magnésio, fósforo e potássio presente no mesmo.

Para classificação do solo aplicou-se a Rede *Feed Forward Backpropagation*, que consiste em um treinamento supervisionado, que busca o melhor treinamento com uma menor taxa de erro. O programa utilizado foi o Matlab. A fertilidade do solo foi dividida em 5 níveis de classificação, em que para cada classificação foi definido uma saída de identificação gerada pela rede. A **tabela 1** apresenta as classificações e suas respectivas saídas, as quais foram utilizadas para treinamento da rede.

**Tabela 1.** Classificações do solo pela sua fertilidade.

Classes	Saída
Solo com fertilidade aparente muito alta	111
Solo com fertilidade aparente alta	101
Solo com fertilidade aparente média	011
Solo com fertilidade aparente baixa	001
Solo com fertilidade aparente muito baixa	010

O treinamento da rede foi composto por duas camadas, sendo uma camada intermediária com 10 neurônios, e uma camada de saída. Para cada classe de fertilidade do solo, existem atributos com restrições específicas para o mesmo. Os atributos e suas respectivas restrições que foram utilizados para treinamento da rede, estão apresentados na **tabela 2** (VAN RAIJ et. al., 1997).

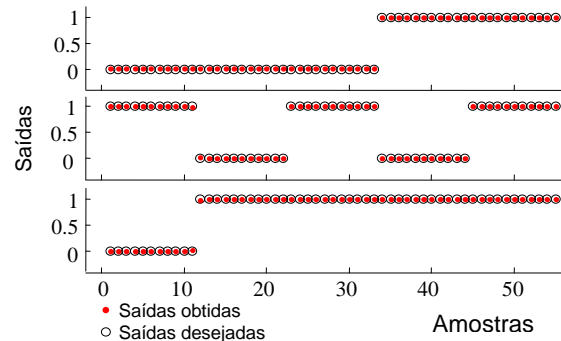
**Tabela 2.** Atributos de classificação.

Atributos	Muito alta	Alta	Média	Baixa	Muito baixa
pH (CaCl <sub>2</sub> )	>6	5,6 - 6,0	5,1 - 5,5	4,4 - 5,0	<4,3
CTC (mmol <sub>c</sub> dm <sup>-3</sup> )	>120	91 - 120	61 - 90	40 - 60	<40
V (%)	>91	71 - 90	51 - 70	26 - 50	≤25
P (mg dm <sup>-3</sup> )	>80	41 - 80	16 - 40	7 - 15	≤6
Mg (mmol <sub>c</sub> dm <sup>-3</sup> )	>12	9 - 11	5 - 8	4 - 1	<1,0
K (mmol <sub>c</sub> dm <sup>-3</sup> )	>6	3,1 - 6	1,6 - 3	0,8 - 1,5	<0,7

Para fase de treinamento foram utilizadas 55 amostras, das quais eram 11 de cada classe de classificação. Dessas 55 amostras foram utilizadas 33 amostras para treinamento (60 %), 11 amostras para validação (20%) e 11 amostras para teste (20%). Ao final do treinamento obteve-se o valor médio dos erros de treinamento das 33 amostras citadas, obtendo um valor médio do erro de  $1,696 \times 10^{-4}$ , ou seja, bem próximo de zero que consiste em um excelente treinamento.

A **figura 1** a seguir representa a minimização do

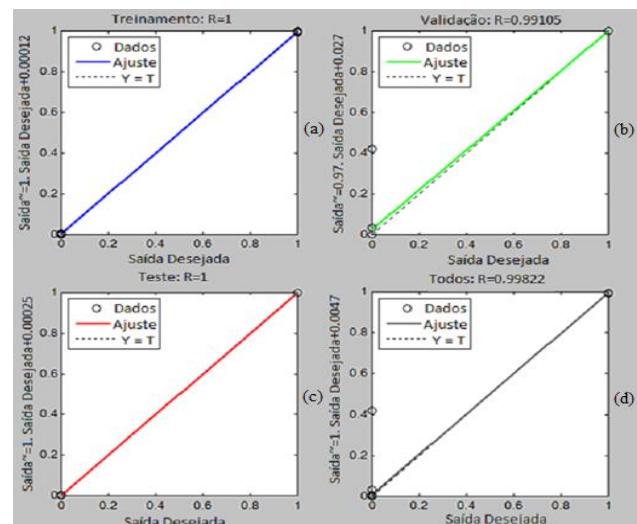
erro na fase de treinamento, o qual os pontos vermelhos representam as saídas obtidas e os círculos representam as saídas desejadas, isso para as 55 amostras utilizadas (100%).



**Figura 1.** Processo de treinamento: Saídas obtidas vs saídas desejadas.

A verificação da qualidade do treinamento da rede pode ser analisada pela regressão dos aspectos do treinamento da rede, em que quando mais próximo do valor 1, melhor é o treinamento, pois consiste na comparação da saída desejada com as saídas obtidas. As regressões do treinamento, da validação, do teste e da soma dos três aspectos está apresentada na **figura 2(a), (b), (c) e (d)** a seguir, com resultados próximos ou iguais a 1.

Outro método de verificação da qualidade do treinamento da rede é o gráfico que apresenta a



**Figura 2.** Retas de regressão, (a) regressão para o treinamento, (b) regressão para a validação, (c) regressão para o teste, (d) regressão para os três aspectos (todos).

melhor performance de validação do treinamento, em que consiste no comparativo do melhor resultado buscado, e do comportamento do treinamento, da validação e do teste na fase de treinamento. A **figura 3** apresenta a melhor performance de validação do treinamento

apresentado no trabalho, ou seja, os valores obtidos do treinamento, validação e teste sejam os mais próximos possíveis de zero. Observa-se que após algumas tentativas para treinar a rede, concluiu-se que a validação e o teste ficaram próximos de  $10^{-7}$  e o treinamento próximo de  $10^{-4}$ , mostrando um excelente desempenho da rede. O erro é mensurado pelo Erro Quadrático Médio (*mean square error* (MSE)) dado pela equação (1), que consiste na diferença dos quadrados médios entre saídas obtidas e saídas desejadas, em que quanto menor seu valor, menor será o erro.

$$MSE = \sum_{i=1}^n [(Y_{obtida} - Y_{desejada})^2 / (n - 2)] \quad (1)$$

Melhor Validação é 1.98e-007 na época 0




Figura 3. Melhor Performance de Validação.

## RESULTADOS E DISCUSSÃO

Após o treinamento, foi realizada a fase de operação da rede de classificação de solos. Foram utilizadas 108 amostras de solos de área degradada em 3 profundidades (0,0-0,1; 0,1-0,2; 0,2-0,4 m). A classificação do solo via RNA teve uma análise geral que gerou os resultados apresentados na **tabela 3**.

**Tabela3.** Resultados da classificação do solo.

Fertilidade	Muito alta	Alta	Média	Baixa	Muito baixa
Amostras	0	0	4	39	65
Percentual	0%	0%	4%	36%	60%

Analisando os resultados determina-se que a área classificada tem sua maior porcentagem de fertilidade aparente muito baixa, assim, estabelecendo processo de recuperação da degradação da qualidade química do solo. Após o resultado geral foi realizada uma classificação específica para cada profundidade (**figura 4(a), (b), (c) e (d)**), mostrando o decréscimo da fertilidade em profundidade.

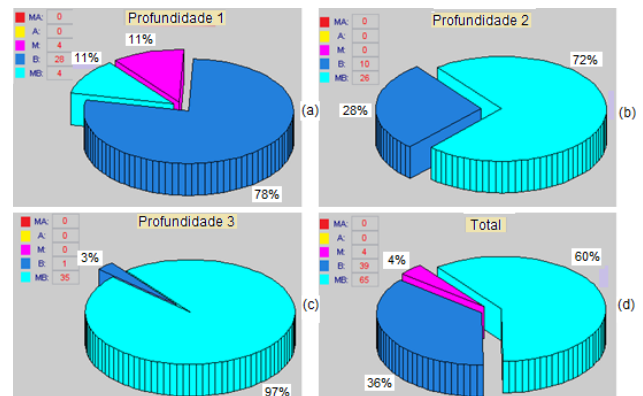


Figura 4. Fertilidade do solo em função da profundidade via RNA, (a) profundidade 1, (b) profundidade 2, (c) profundidade (3), (d) total de amostras.

Em relação aos tratamentos de recuperação, verificou-se que os tratamentos com adubos verdes +calcário+gesso e/ou calcário+adubos verdes foram os mais eficientes em recuperar a qualidade química do solo na profundidade de 0,0-0,1 m. Os valores obtidos estão na faixa de média e baixa fertilidade do solo (**figura 5(a), (b), (c) e (d)**), concordando com os dados analisados pela estatística clássica em Bonini (2012). Essa comparação confirma a eficiência das RNA para classificação da fertilidade do solo.

Para os tratamentos de recuperação com adubos verdes ou só com preparo do solo não houve acréscimo nos níveis de fertilidade do solo (**figura 5(e), (f), (g) e (h)**). Esses resultados discordam dos obtidos por Bonini et al (2015) e Alves e Souza (2011) que estudando a recuperação da qualidade química do solo verificaram que a adição de matéria orgânica no solo eleva a sua fertilidade.

Nas camadas subsuperficiais (0,1-0,2 e 0,2-0,4 m) os efeitos dos tratamentos de recuperação não foram eficientes.

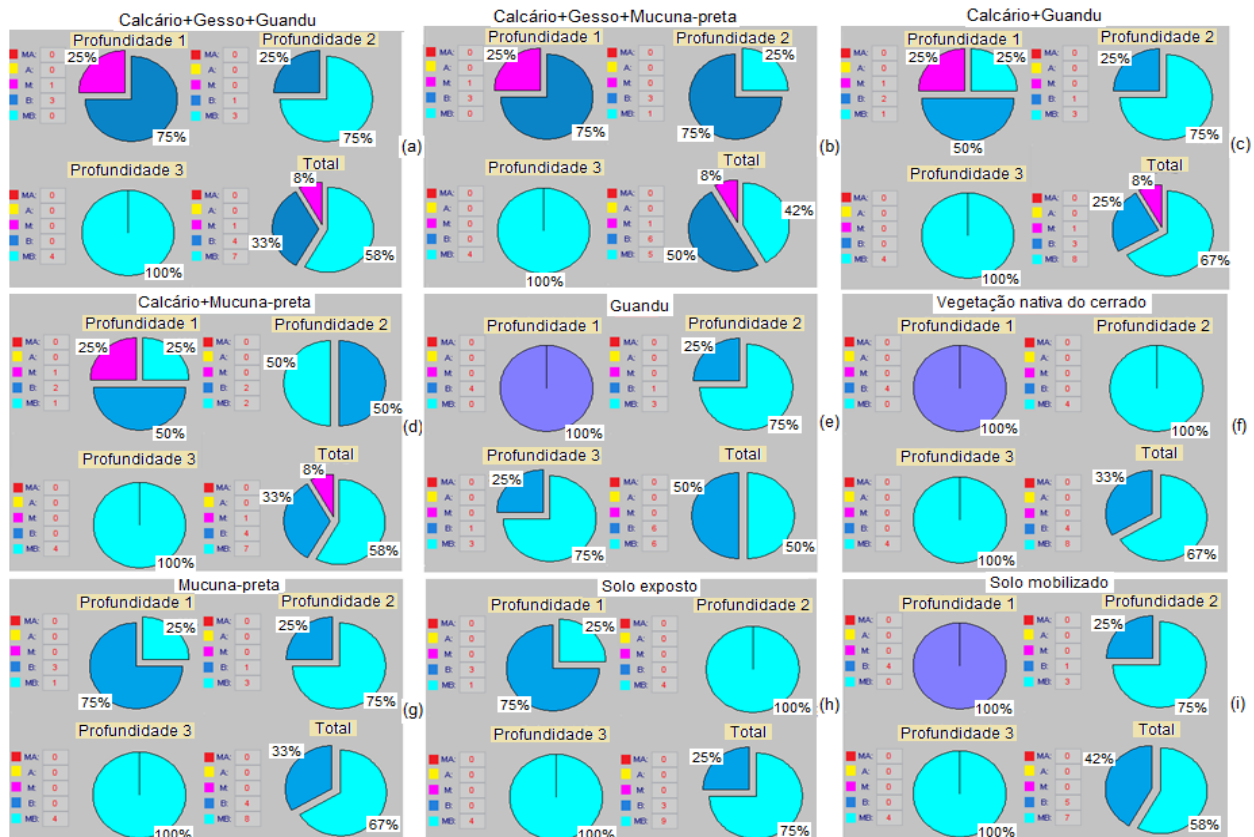
## CONCLUSÕES

A aplicação da Rede Neural Artificial Retropropagação, fase de treinamento e classificação apresentou um excelente resultado.

A RNA mostrou uma ferramenta confiável com erro de  $1,696 \times 10^{-4}$  para o treinamento, sendo eficiente e assim obteve valores equivalentes a estatística clássica mas com melhor agrupamento dos dados facilitando a sua discussão.

## AGRADECIMENTOS

Os autores agradecem a Pró-Reitoria de Pesquisa da UNESP (PROPe) pelo apoio financeiro.



**Figura 5.** Fertilidade do solo em função dos tratamentos e profundidade, (a) calcário+gesso+guandu, (b) calcário+gesso+mucuna-preta, (c) calcário+guandu, (d) calcário+mucuna-preta, (e) guandu, (f) vegetação nativa do cerrado, (g) mucuna-preta, (h) solo exposto, (i) solo mobilizado

## REFERÊNCIAS

ALVES, M. C. e SOUZA, Z. M. Recuperação do subsolo em área de empréstimo usada para construção de hidroelétrica. *Rev. Cie. Agrônômica*, 42:301-309, 2011.

ANAGU, I.; INGWERSEN, J.; UTERMANN, J. and STRECK, T. Estimation of heavy metal sorption in German soils using artificial neural networks. *Geoderma*, 152:104-112. 2009.

BONINI, C. S. B.; ALVES, M. C. e MONTANARI, R. Lodo de esgoto e adubação mineral na recuperação de atributos químicos de solo degradado. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 19: 388-393, 2015.

BONINI, C. S. B. Restauração ecológica de um solo decapitado sob intervenção antrópica há 17 anos. 191 f. Tese (Doutorado em Agronomia) – Faculdade de Engenharia de Ilha Solteira, UNESP, 2012.

BEUCHERA, A.; SIEMSSENA, R.; FRÖJDÖA, S.; ÖSTERHOLMA, P.; MARTINKAUPPIB, A. and EDÉN, P. Artificial neural network for mapping and characterization of acid sulfate soils: Application to Sirppujoki River catchment, southwestern Finland. *Geoderma*. 247–248:38–50, 2015.

BUCENE, L. C.; RODRIGUES, L. H. A. Utilização das Redes Neurais Artificiais para avaliação da produtividade do solo, visando classificação de terras para

irrigação. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, 8:326-329, 2004.

CURI, T. M. R. de C.; DE MOURA D. J.; MASSARI, J. M.; VERCELLINO, R. A.; SABINO, L. A. Redes Neurais na predição da vazão ideal de exaustores em aviários de frango de corte com diferentes topologias. In: Congresso Brasileiro de Engenharia Agrícola, 43., 2014.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Ministério da Agricultura, Pecuária e Abastecimento. Sistema Brasileiro de Classificação de Solos. 2013. 3.ed. Rio de Janeiro: Embrapa CNPSO, 306p.

RAIJ, B. VAN.; CANTARELLA, H.; QUAGGIO, J. A.; FURLANI, A. M. C. Recomendações de adubação e calagem para o Estado de São Paulo. 2. ed. Campinas: Instituto Agronômico: Fundação IAC, 1997. p. 30-35 (Boletim técnico, 100).

SILVEIRA, C. T.; OKA-FIORI, C.; SANTOS, L. J. C.; SIRTOLI, A. E.; SILVA, C. R.; BOTELHO, M. F. Soil prediction using artificial neural networks and topographic attributes. *Geoderma*, 195–196:165-172, 2013.

SOARES, F. C.; RUSSI, J. L.; ROBAINA, A. D. PEITER, M. X.; PARIZI, A. R. C. Uso de Rede Neural Artificial para predição da produção na cultura do feijoeiro. In: Congresso Brasileiro de Engenharia Agrícola, 43., 2014.