

Sistema de Inferência Neuro-Fuzzy para Análise Microbiológica de Processos de Compostagem

Vania Mota* Daniel Leite**

* *Fundação Universidade Federal de Rondônia (UNIR), Brasil,
(e-mail: vania.mota@unir.br)*

** *Universidade Federal de Lavras (UFLA), MG, Brasil
(e-mail: daniel.leite@ufla.br)*

Abstract: The bed of confinement sheds of dairy cattle in the compost barn model has a great impact on the quality and animal productivity. The objective of this study is to develop a nonlinear model to estimate the amount of bacteria on compost barn beds. From easy-to-measure variables, estimates are given by the model and, therefore, expensive and lengthy laboratory analyses are avoided. A neuro-fuzzy inference model, ANFIS, is considered. The research was carried out in a property in Tres Coracoes. Different fuzzy membership functions and learning algorithms, such as Fuzzy C-Means and Error Backpropagation, were evaluated on the construction of the ANFIS model. Results show that ANFIS can predict the overall bacteria count with good accuracy. The best ANFIS setting uses five easily measurable attributes (pH, moisture, temperature at surface and at 0.15m deep, and fixed mineral residue); Gaussian membership functions properly placed in the data space via Fuzzy C-Means clustering; and the Backpropagation algorithm to adapt the coefficients of affine consequent functions. Moreover, a simplified model with four attributes – excluded the fixed mineral residue – using generalized bell membership function is suggested alternatively at the price of a slight reduction in accuracy.

Resumo: A cama de galpões de confinamento de bovino leiteiro no modelo *compost barn* tem grande impacto na qualidade e produtividade animal. O objetivo deste estudo é desenvolver um modelo não-linear para estimar a quantidade de bactéria em camas de compostagem. A partir de variáveis de fácil mensuração, estimativas podem ser geradas pelo modelo e, conseqüentemente, análises laboratoriais caras e demoradas são evitadas. Um modelo de inferência neuro-fuzzy, ANFIS, é considerado. A pesquisa foi realizada em uma propriedade em Três Corações. Diferentes funções de pertinência fuzzy e algoritmos de aprendizado, tais como Fuzzy C-Means e Retro-Propagação de Erro, foram avaliados na construção do modelo ANFIS. Os resultados mostram que ANFIS prediz a contagem total de bactérias com boa acurácia. A melhor configuração ANFIS usa cinco atributos facilmente mensuráveis (pH, umidade, temperatura na superfície e a 0,15m de profundidade, e resíduo mineral fixo); funções de pertinência Gaussianas apropriadamente posicionadas no espaço dos dados via Fuzzy C-Means; e o algoritmo de retro-propagação para adaptar os coeficientes de funções conseqüentes afins. Ademais, um modelo simplificado com quatro atributos – excluído o resíduo mineral fixo – usando função de pertinência sino generalizado é sugerido alternativamente ao preço de uma pequena redução em acurácia.

Keywords: Neuro-Fuzzy Network, Microbiological Analysis, Computational Intelligence.

Palavras-chaves: Rede Neuro-Fuzzy, Análise Microbiológica, Inteligência Computacional.

1. INTRODUÇÃO

1.1 Breve Contextualização

A cama para galpões de confinamento para bovinos leiteiros no modelo *Compost Barn* apresenta grande impacto na qualidade e na produtividade desses galpões, sendo um item de grande importância para o manejo e sucesso desse tipo de confinamento. O material de cama oferece condições de porosidade e manutenção da umidade, com rápida degradação de matéria orgânica. Esse processo necessita de um equilíbrio contínuo de oxigênio, carbono e nitrogênio.

O oxigênio do composto vem do revolvimento da cama e do ar que difunde para a superfície da cama (Mota et al., 2019b; Leso et al., 2019).

A compostagem consiste de uma mistura de fonte de carbono fornecido pela cama e o material orgânico rico em nitrogênio originário das fezes e urina animal (Black et al., 2014; Mota et al., 2017a). A cama precisa ser revolvida frequentemente conforme relatado em vários estudos (Leso et al., 2013; Black et al., 2014). A temperatura média conveniente deve estar entre 54,4 e 65,5 °C (Janni et al., 2007); a umidade ideal da cama deve variar de 40 a 60%

(Black et al., 2014); a relação C:N de 25:1 a 30:1; e a densidade de animais recomendada é 7,4 a 12,5 m^2 por animal (Janni et al., 2007; Galama, 2011).

Os materiais utilizados como cama mais comuns são serragem, aparas de madeira e cavacos de madeira. Materiais de partículas pequenas, como a palha finamente processada, palhada de milho e subproduto de palha de trigo também podem ser utilizados (Galama, 2015; Mota et al., 2017, 2018). Observa-se a importância do estudo do material de cama utilizado e o conhecimento das variáveis temperatura da cama, umidade, pH, relação C:N, aeração, quantidade de matéria orgânica e atividade das bactérias e dos microorganismos, para avaliação da eficiência da compostagem.

Outro fator indispensável para o manejo adequado desse sistema de confinamento é manter as características físico-químicas adequadas no substrato da cama a fim de promover a atividade microbiana aeróbia (Black et al., 2014). Conhecer os fatores de compostagem da cama é um aspecto crucial para produtores de bovinos leiteiros. Eles auxiliam tomadas de decisão sobre uma diversidade de opções de utilização da cama. A cama pode ser aplicada no ambiente urbano (em hortas e jardins) ou rural, agregando valor a propriedade (Mota et al., 2019).

1.2 Modelagem Fuzzy para Análise Microbiológica

Há estudos sobre modelagem computacional das condições da cama de compostagem no interior de galpões de produção intensiva (Dinca et al., 2016; Salehi et al., 2014; Mota et al., 2018; Mota, 2018), bem como estudos relacionados aos fatores de compostagem como (Giusti & Libelli, 2010; Neugebauer et al., 2014). A decomposição do substrato sob a ação de várias espécies de bactérias é denominada compostagem – um processo bioquímico de digestão anaeróbica, sendo utilizado em larga escala para o tratamento e recuperação de resíduos biodegradáveis, como na produção de biogás (Salehi et al., 2014; Yordanova et al., 2004, 2006). Particularmente, os métodos de modelagem considerados neste trabalho são métodos fuzzy e neuro-fuzzy (Takagi & Sugeno, 1985; Leite et al., 2013; Rubio et al., 2019). Os modelos visam estimar o número total de bactérias a partir de variáveis mensuráveis ou obtidas em análises laboratoriais, como pH, umidade, matéria orgânica, carbono, resíduo mineral fixo, proteína, nitrogênio, nitrogênio amoniacal e temperatura.

Modelos fuzzy e neuro-fuzzy são motivados pela necessidade de resultados melhores em problemas não-lineares complicados, incluindo classificação, clusterização, predição e aproximação de função. Métodos de aprendizado de máquina têm provido meios para obtenção de modelos não-lineares precisos em diferentes áreas (Leite et al., 2020), incluindo análises microbiológicas e tomada de decisão em pecuária (Mota et al., 2018). Por exemplo, (Shahinfar et al., 2012) usa um método neuro-fuzzy para estimar o nível de reprodução de bovinos.

Um modelo ANFIS (*Adaptive Neuro-Fuzzy Inference System*) é proposto para prever os níveis de biogás em (Yordanova et al., 2004, 2006; Salehi et al., 2014). ANFIS é também usado em (Zareei & Khodaei, 2017) para otimizar a produção de biogás a partir da digestão anaeróbia baseada em conteúdo sólido, taxa carbono-nitrogênio e

frequência de revolvimento de cama. Uma taxa 8% maior na produção de biogás foi alcançada e estatisticamente provada. Em (Sefeedpari et al., 2015), sugere-se que ANFIS supera outros modelos neurais em um problema de predição da produção de leite com base em atributos de energia consumida por vacas.

ANFIS é um ambiente conexionista para representar um sistema de inferência fuzzy Takagi-Sugeno em forma de grafo. A ideia é preservar as vantagens inerentes à modelos fuzzy funcionais, tais como interpretabilidade por meio de regras linguísticas, e habilidade de lidar com incerteza, e, ao mesmo tempo, tomar vantagem de um número de algoritmos de aprendizado para ajustar os parâmetros de redes neurais. Tais algoritmos são fundamentados na teoria de otimização não-linear.

Não existem estudos da aplicação de redes ANFIS para predição do número de bactérias e micro-organismos em processo de compostagem. O propósito do desenvolvimento de tal preditor ANFIS neste trabalho é evitar análises laboratoriais caras para levantamento do quão eficiente tem sido a compostagem de camas que dão suporte ao bem-estar dos animais para uma maior produtividade. Queremos usar atributos fáceis e baratos de se mensurar, como umidade, temperatura e pH, para inferir o número de bactérias.

ANFIS pode ser construído a partir de dados e de conhecimento especialista (Leite et al., 2013). Neste artigo o modelo ANFIS é desenvolvido a partir de dados de sensores de baixo custo e análises laboratoriais (fase de treinamento). Em seguida, o modelo ANFIS é apenas alimentado com dados de sensores e provê uma estimativa do número de bactérias (fase de teste do modelo). O aprendizado dos parâmetros de ANFIS é realizado por meio do algoritmo de clusterização Fuzzy C-Means (FCM), e de uma variante de algoritmo de gradiente para ajuste de parâmetros das funções lineares consequentes. Avaliamos diferentes funções de pertinência e consequentes de ordem 0 e 1.

2. MODELAGEM NEURO-FUZZY

Sistemas neuro-fuzzy adaptativos combinam as características de flexibilidade (modelos locais ajustáveis) e interpretabilidade de sistemas fuzzy com a arquitetura de uma rede neural e seus vários algoritmos de treinamento, bem fundamentados na teoria de otimização, e bem aceitos pela comunidade de inteligência computacional. Por exemplo, um modelo ANFIS é um modelo fuzzy Takagi-Sugeno de primeira ordem disposto ao de 5 camadas de uma rede neural *feed-forward* (Jang, 1993) (Takagi & Sugeno, 1985) (Ludwig Júnior; Schnitman; Lepikson, 2004).

As funções de pertinências e as regras fuzzy de um modelo ANFIS são definidas a partir de dados de entrada e saída e de um algoritmo de treinamento. A Fig. 1 mostra a arquitetura de um modelo ANFIS com duas regras, dois atributos de entrada e duas funções de pertinência por atributo.

Frequentemente, um modelo ANFIS possui variável de saída única, proveniente da agregação média aritmética ponderada das contribuições locais. A função local associada a uma regra fuzzy pode ser constante (modelo de

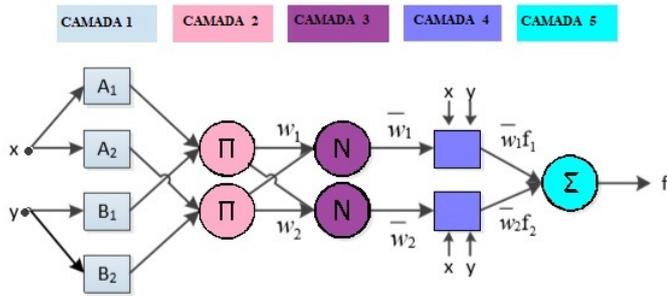


Figura 1. Arquitetura de um modelo ANFIS

ordem 0) ou linear (modelo de ordem 1). Baseado na Fig. 1, temos duas regras fuzzy, conforme:

Regra 1: SE x é A_1 E y é B_1 ,

ENTÃO $f_1 = p_1x + q_1y + r_1$

Regra 2: SE x é A_2 E y é B_2 ,

ENTÃO $f_2 = p_2x + q_2y + r_2$

em que x e y são as entradas; A_i e B_i são conjuntos fuzzy ($i = 1, 2$); f_i é a estimativa local especificada pela i -ésima regra fuzzy; p_i , q_i e r_i são parâmetros a serem determinados pelo algoritmo de treinamento. Na Fig. 1, um círculo indica um nó fixo, enquanto um quadrado indica um nó adaptativo.

ANFIS consiste de 5 camadas (Fig. 1) contendo elementos que não são totalmente conectados. Cada camada tem um papel específico:

- Camada 1: o grau de pertinência de cada entrada é calculado. Os atributos x e y compõem o vetor de entrada, e A_i e B_i são funções de pertinência. Avaliamos quatro tipos de funções: triangular, trapezoidal, sino generalizado e Gaussiana. Os parâmetros das funções são ajustados por um algoritmo de aprendizado. Logo, não se trata de funções simétricas ao longo do domínio dos atributos. Graus de pertinência são dados por

$$D_{1,i} = \mu_{A_i}(x), \quad i = 1, 2, \quad (1)$$

$$D_{1,i} = \mu_{B_{i-2}}(y), \quad i = 3, 4, \quad (2)$$

em que x e y são as entradas do i -ésimo nó, e A_i e B_i são valores linguísticos associados às funções de pertinência. $\mu_{A_i}(x)$ e $\mu_{B_{i-2}}(y)$ podem ser qualquer função. Por exemplo, se uma Gaussiana é empregada, $\mu_{A_i}(x)$ é dada por

$$\mu_{A_i}(x) = e^{-\frac{1}{2} \left(\frac{x-c_i}{a_i} \right)^2}, \quad (3)$$

em que a_i e c_i são o desvio padrão e a média.

- Camada 2: contém neurônios que operam a agregação T-norma produto algébrico. A saída desta camada é

$$D_{2,i} = \mu_{A_i}(x) \mu_{B_{i-2}}(y), \quad i = 1, 2. \quad (4)$$

- Camada 3: procede reescalonamento de valores tal que o somatório dos disparos de todas as regras, $\sum_i \bar{w}_i$, é igual a 1. A i -ésima saída é

$$D_{3,i} = (\bar{w}_i) = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2. \quad (5)$$

- Camada 4: emprega funções algébricas de ordem 0 (uma constante) ou de ordem 1 (linear), típicas de sistemas fuzzy Takagi-Sugeno. No caso geral (ordem 1), a saída de um elemento da camada é

$$D_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2, \quad (6)$$

em que p_i , q_i e r_i são coeficientes ajustados via algoritmo de Mínimos Quadrados.

- Camada 5: agrega as contribuições locais das regras em uma estimativa global. A saída é

$$D_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (7)$$

O treinamento de um modelo ANFIS contém duas etapas. Primeiro é escolhida uma arquitetura para o sistema de inferência fuzzy (FIS). Em seguida, aplica-se uma combinação de algoritmos. Um algoritmo para adaptação dos coeficientes da Camada 4, geralmente baseado em mínimos quadrados ou gradiente; e um algoritmo para adaptação dos parâmetros das funções de pertinência da Camada 2. Geralmente procede-se algumas iterações do algoritmo Fuzzy C-Means ou algoritmo de Gradiente após retro-propagação de erros de estimativa.

Em (Al-Hmouz et al., 2012), menciona-se que ANFIS torna as regras SE-ENTÃO que descrevem o comportamento de um sistema mais preciso. O ambiente permite ajuste fino de parâmetros de modelos fuzzy a partir de dados, e não requer conhecimento humano sobre o problema e o modelo em questão. Ressalta-se cuidados com relação ao problema da *maldição da dimensionalidade*, que consiste no aumento exponencial do número de parâmetros a serem adaptados dependendo dos atributos do problema e aspectos do modelo (Faustino, 2011).

Para sistemas multivariados não-lineares é interessante a partição da base de dados usando algum algoritmo de clusterização fuzzy. Clusters reduzem o problema da dimensionalidade no sentido vertical, i.e., com relação ao número de amostras. O procedimento reduz o número de regras fuzzy produzidas, quando comparado com partição em *grid* ou árvore, e permite uma melhor interpretação do modelo resultante (Silva; Silva; Teixeira, 2012). Neste artigo, para lidar com tal questão, será aplicado inicialmente o algoritmo Fuzzy C-Means para particionamento via *scattering* dos dados de treinamento e inicialização do modelo ANFIS.

3. METODOLOGIA

3.1 Sobre a Coleta de Dados

A pesquisa foi realizada a partir da análise microbiológica de uma cama de composto (área de descanso) de um confinamento de bovinos leiteiros no modelo *Compost Barn* em uma propriedade de Três Corações, Minas Gerais. Segundo a classificação internacional de Köppen, o clima da região é do tipo CWA, caracterizado por duas estações bem definidas: uma seca e de menores temperaturas, que se estende de maio a setembro; e outra úmida e de temperaturas mais elevadas, de outubro a abril. A temperatura média anual é de 20,2° C e a precipitação anual é de 1401 mm.

O galpão de confinamento tem orientação NO/SO. Possui 18,7 m de largura por 50 m de comprimento; pé direito 4 m, e espigão 6 m. Destes, 13 m x 50 m é destinado a área da cama, dividida em 3 lotes (alta produção de leite, média produção de leite e baixa produção de leite), separados por meio de cerca elétrica. Esta área é utilizada para análise. Possui ainda 3 cochos de mineral e cinco ventiladores de 6 hélices centralizados a uma altura de 3,2 m na área de descanso. Cada ventilador proporciona uma vazão de 48000 m³/hora (Fig. 2). Os dados foram coletados no verão de 2016 - tratamento (VER), e inverno de 2016 - tratamento (INV); em 6 períodos de 3 dias de coleta em VER (P1, P2, P3) e 3 dias em INV (P4, P5, P6).

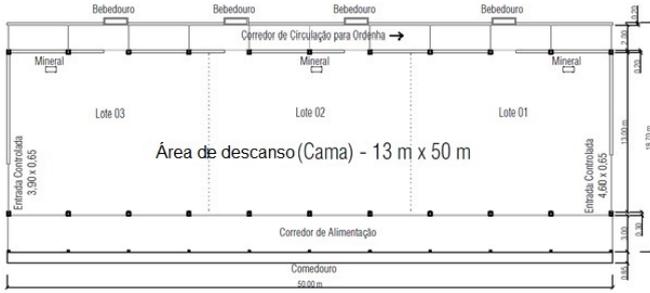


Figura 2. Detalhe do galpão de coleta de composto

3.2 Atributos e Estrutura ANFIS

Seja x o vetor de entrada de ANFIS, e y a saída correspondente. Os atributos de x são: x_1 , pH; x_2 , umidade da cama (%); x_3 , matéria orgânica; x_4 , carbono total (%); x_5 , resíduo mineral fixo (cinzas); x_6 , proteína; x_7 , nitrogênio total (%); x_8 , nitrogênio amoniacal (%); x_9 , temperatura da cama a 0,15 m (°C); x_{10} , temperatura superficial da cama (°C). A saída, y , é o número total de bactérias.

A partir de análise de correlação de Pearson, os atributos mais correlacionados são analisados utilizando procedimentos de análise estatística descritiva, como média, desvio padrão, coeficiente de variação e valores mínimos e máximos (Banzatto & Kronka, 2015). Admitiu-se um nível de significância $\alpha > 0,05$. As análises estatísticas foram realizadas no software R (Core Team, 2018). Posteriormente, os dados são submetidos ao modelo ANFIS.

O modelo ANFIS-1 processa apenas os atributos x_1 , x_2 , x_5 , x_9 e x_{10} . Estes atributos são menos correlacionados entre si e mais correlacionados com a saída y . A estrutura de ANFIS-1 com 5 entradas e duas funções de pertinência por entrada é mostrada na Fig. 3. O modelo contém 2⁵ ou 32 regras. Os demais atributos são desconsiderados neste artigo. O modelo ANFIS-2 possui estrutura ainda mais compacta, com apenas 4 dentre os 5 atributos de ANFIS-1 e, portanto, 16 regras. Os atributos são x_1 , x_2 , x_9 e x_{10} ; eles não requerem análise em laboratório e são facilmente mensurados com equipamento portátil. Foi utilizado o software Matlab para projeto (Matlab, 1991).

3.3 Medida de Desempenho

Avaliamos 4 tipos de funções de pertinência: triangular (trimf), trapezoidal (trapmf), sino generalizada (gbellmf), e Gaussiana (gaussmf). Avaliamos consequentes de ordem

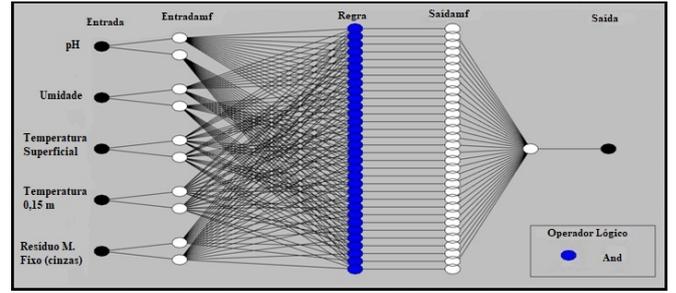


Figura 3. Estrutura do modelo ANFIS-1

0 (constante) e 1 (linear). Similar a (Leite & Skrjanc, 2019; Soares et al., 2017), usamos a raiz do erro médio quadrado ($RMSE$) como medida de desempenho,

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\bar{y}_i - y_i)^2} \quad (8)$$

em que y é o valor real, \bar{y} é a estimacão, e N é o número de amostras.

4. RESULTADOS

Valores estatísticos da base de dados são mostrados na Tabela 1. Observa-se que a temperatura mínima média na profundidade de 0,15 m é de 25,2 °C, o que é abaixo do ideal nesse modelo de confinamento. A temperatura média indicada de acordo (Leso et al., 2013) e (Black et al., 2014) deve estar entre 54,4 e 65,5 °C. A temperatura máxima na profundidade de 0,15 m é de 56,3 °C, o que segue o recomendado.

Tabela 1. Resultado da análise estatística dos atributos de ANFIS-1

Var.	x_1	x_2	x_5	x_9	x_{10}
Média	9,346	50,561	15,981	34,551	22,092
Mínimo	6,704	14,101	0,047	25,175	11,550
Máximo	10,280	90,218	41,603	56,300	33,550
S.D*	0,545	11,192	10,161	5,362	4,294
C.V.% **	5,837	22,135	63,583	15,519	19,440

* SD: Desvio padrão; **C.V.%: Coeficiente de variação

Observa-se que a temperatura superficial mínima, média e máxima está dentro do esperado. O coeficiente de variação expressa a variabilidade dos dados. Quanto menor $C.V.$, menor a dispersão em torno da média (Banzatto & Kronka, 2015). O pH apresentou baixo coeficiente ($C.V. \leq 10\%$), indicando homogeneidade dos dados e baixa dispersão. A temperatura superficial e a 0,15 m apresentou valor médio de coeficiente de variação ($C.V. \in [10\ 20]\%$), enquanto os outros atributos apresentaram alta variabilidade.

Avaliamos os modelos ANFIS-1 e ANFIS-2 na estimacão do número total de bactérias para compostagem a partir de 5 e 4 atributos de entrada, respectivamente. Quatro funções de pertinência foram avaliadas. Consequente Takagi-Sugeno constante e linear foram avaliados. Os resultados de treino e teste estão reportados na Tabela 2.

O melhor desempenho de ANFIS-1 em teste ($RMSE = 0,0973$) é obtido usando funções de pertinência Gaussiana e consequente de primeira ordem. Este modelo generaliza

Tabela 2. Raiz do Erro Quadrado Médio para modelos ANFIS preditores do número de bactérias

–	Modelo ANFIS-1 com 5 atributos				Modelo ANFIS-2 com 4 atributos			
	Consequente ordem 0		Consequente linear		Consequente ordem 0		Consequente linear	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
Função de pertinência								
Trimf	0,1375	0,1403	0,1459	0,1457	0,1058	0,1078	0,0998	0,0999
Trapmf	0,2336	0,2481	0,1651	0,1765	0,1551	0,1664	0,1444	0,1486
Gaussmf	0,1047	0,1051	0,0951	0,0973	0,1078	0,1095	0,1006	0,1015
Gbellmf	0,1211	0,1205	0,1137	0,1085	0,1059	0,1074	0,0975	0,0990

melhor os padrões encontrados nos dados de treinamento. Validação cruzada é automaticamente considerada pelo algoritmo de treinamento para evitar *overfitting*. O melhor desempenho de ANFIS-2 em teste ($RMSE = 0,0990$) é obtido usando funções de pertinência sino e consequente linear. Em ANFIS-2 abre-se mão de um valor de acurácia de estimação ligeiramente melhor oferecido por ANFIS-1 com o objetivo de comprimir o modelo em 16 regras fuzzy somente – ao invés de 32 regras em ANFIS-1 – e eliminação do atributo x_5 , resíduo mineral fixo.

Um exemplo de curva de aproximação da quantidade de bactérias – em particular a curva fornecida pelo melhor modelo ANFIS-1 – é mostrada na Fig. 4. Nota-se que os picos de maior amplitude da curva real não são atingidos pelas estimações – o que é positivo, pois mostra que o modelo não está sobre-ajustado. Em geral, as estimações seguiram o comportamento essencial da função real.

O modelo ANFIS-2 apresenta interpretação mais fácil para suporte à tomada de decisão por parte do produtor e usa atributos rápidos de serem mensurados, viz., pH, umidade e temperatura. Com este modelo, análises laboratoriais são evitadas. A estimação do número total de bactérias para o sucesso da compostagem podem agregar valor a propriedade e ao material em si, que pode ser usado ou vendido como fertilizante.

ANFIS combina a capacidade de aprendizado a partir de dados de redes neurais com a capacidade de interpretação linguística de sistemas fuzzy. Logo, concluímos que o estudo teve relativo sucesso em termos de desempenho do modelo, além de prover informação adicional que pode ser usada subjetivamente para diferentes propósitos.

5. CONCLUSÃO

Apresentamos modelos neuro-fuzzy ANFIS para estimar a quantidade de bactérias em camas de compostagem comumente encontradas em sistemas de confinamento *Compost Barn*. A ideia é evitar análises laboratoriais. Os atributos processados pelos modelos (pH, umidade e temperatura) são fáceis de mensurar em campo. Os modelos foram projetados via algoritmos Fuzzy C-Means e retro-propagação de erro a partir de dados de uma propriedade em Três Corações. Diferentes tipos de funções de pertinência fuzzy e consequentes de regras de ordem 0 e 1 também foram avaliados. Um valor de RMSE para dados de teste de 0,990 foi obtido para o modelo simplificado, i.e., com 4 atributos – excluído o resíduo mineral fixo. Esse modelo usa funções sino generalizado e consequente linear. O melhor RMSE, 0,973, foi obtido para o modelo que usa 5 atributos e função Gaussiana. No futuro, coletaremos dados por um período de tempo maior considerando outras propriedades que utilizam o sistema de confinamento baseado em cama

de compostagem. Uma maior quantidade de dados tende a fornecer resultados superiores em abordagens neuro-fuzzy e modelos profundos (*deep models*), visto que estes possuem um número grande de parâmetros.

AGRADECIMENTOS

A primeira autora agradece à Coordenação de Aperfeiçoamento de Pessoal de Ensino Superior (CAPES) pelo apoio. Este trabalho recebeu apoio do Instituto Serrapilheira (número do processo Serra - 1812-26777).

REFERÊNCIAS

- A. Al-Hmouz; J. Shen; R. Al-Hmouz; J. Yan. Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning. *In: IEEE Transactions on Learning Technologies*, 5(3), 226-237, 2012.
- D. A. Banzatto; S. N. Kronka. *Experimentação Agrícola*, 4 ed. Jaboticabal, Funep, 2015.
- R. A. Black; J. L. Taraba; G. B. Day; F. A. Damasceno; M. C. Newman; K. A. Akers; C. L. Wood; K. J. McQuerry; J. M. Bewley. The Relationship between Compost Bedded Pack Performance, Management, and Bacterial Counts. *Journal of Dairy Science*, 97, 2669-2679, 2014.
- M. Dinca; G. Voicu; M. Ferdes; L. Toma; I. Voicea. Anaerobic digestion of animal manure and maize silage in pilot plant for biogas production. *U.P.B. Sci. Bull.*, 78(2), 71-80, 2016.
- C. P. Faustino. Previsão de Séries Temporais via Modelos Baseados em Regras. *Dissertação* Universidade Federal de Itajubá, (UNIFEI), 2011.
- P. J. Galama. *Prospects for Bedded Pack Barns for Dairy Cattle*. Wageningen UR Livestock Research, Lelystad - The Netherlands (Report), 2011.
- P. J. Galama; H. C. de Boer; H. J. C. Dooren Van; W. Ouweltjes; F. Driehuis. *Sustainability aspects of ten bedded pack dairy barns in the Netherlands*. Wageningen: Livestock Research, 1-83, 2015.
- E. Giusti; S. Marsili-Libelli. Fuzzy Modelling of the Composting Process. *Environ. Model. Softw.*, 25, 641-647, 2010.
- K. A. Janni; et al. Compost Dairy Barn Layout and Management Recommendations. *Appl. Eng. Agric.*, 23(1), 97-102, 2007.
- J. S. R. Jang. ANFIS: Adaptive-Network-based Fuzzy Inference System. *IEEE Transactions on Systems Man and Cybernetics*, 23, 665-685, 1993.
- D. Leite, I. Skrjanc, F. Gomide. An Overview on Evolving Systems and Learning from Stream Data. *Evolving Systems*, 11, 181-198, 2020.
- D. Leite, I. Skrjanc. Ensemble of Evolving Optimal Granular Experts, OWA Aggregation, and Time Series Prediction. *Information Sciences*, 504, 95-112, 2019.

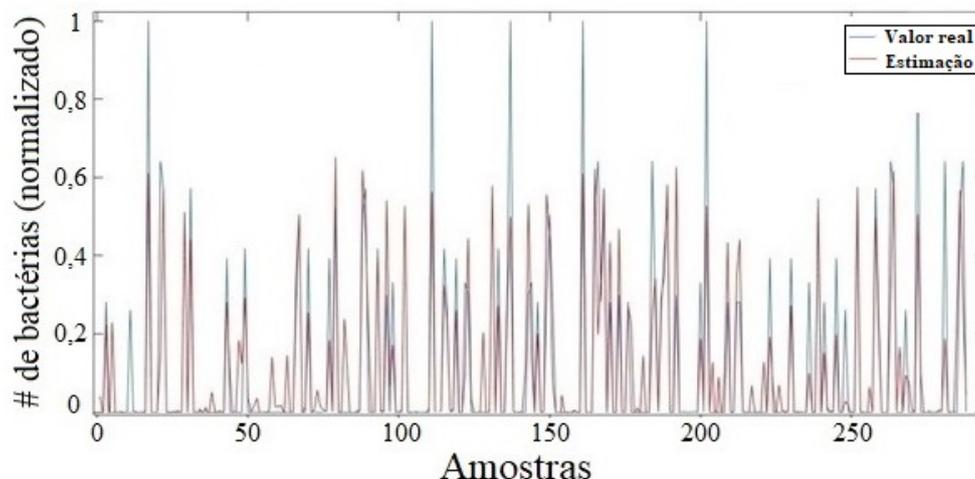


Figura 4. Estimação da quantidade de bactérias usando o modelo ANFIS-1, com 5 entradas, função de pertinência Gaussiana e função consequente linear

- D. Leite, P. Costa, F. Gomide. Evolving Granular Neural Networks from Fuzzy Data Streams. *Neural Networks*, 38, 1–16, 2013.
- L. Leso; M. Uberti; W. Morshed; M. Barbari. A Survey of Italian Compost Dairy Barns. *J. Agric. Eng.*, 44(3), 120-124, 2013.
- L. Leso; P. Ferraz; G. Ferraz; M. Barbari. Measurements Relationship among Compost Bedded Pack Barn Farms in Six European Countries during the Winter and Spring Season. *II Simpósio Internacional de Ambiência na Produção Animal Sustentável*, 998-1005, 2009.
- O. Ludwig Júnior; L. Schnitman; H. Lepikson. Uma Arquitetura Neural Híbrida para Extração de Regras Nebulosas. In: *IEEE Latin A. Tran.*, 2(2), 2004.
- V. Mota; A. Campos; F. Damasceno; E. Resende; C. Rezende; L. R. Abreu; T. Vareiro. Confinamento para Bovinos Leiteiros: Histórico e características. *PUBVET*, 11, 433-442, 2017.
- V. Mota; F. Damasceno; E. Soares; D. Leite. Fuzzy Clustering Methods Applied to the Evaluation of Compost Bedded Pack Barns. *IEEE Int. Conf. on Fuzzy Systems (FUZZ-IEEE)*, Naples, 6p. 2017.
- V. Mota; F. Damasceno; D. Leite. Fuzzy Clustering and Fuzzy Validity Measures for Knowledge Discovery and Decision Making in Agricultural Engineering. *Computers and Electronics in Agriculture*, 150, 118-124, 2018.
- V. Mota. Modelagem Fuzzy, Geoestatística e Estatística na Avaliação de Sistemas de Confinamento para Bovinos no Modelo Compost Barn. Tese Doutorado, Universidade Federal de Lavras (UFLA), 2018.
- V. Mota; E. Andrade; S. Pinto; L. R. Abreu; D. Leite. Utilization of Bedded Cattle Confinement for Organic Manure of Maize Crop. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 23(8), 620-624, 2019.
- V. Mota; E. Andrade; D. Leite. Bed Temperature in Compost Barns Turned with Rotary Hoe and Offset Disc Harrow. *Engenharia Agrícola*, 39(3), 280-287, 2019.
- MATLAB for Windows User's Guide*. The Math Works Inc., 1991.
- M. Neugebauer; P. Solowiej; J. Piechocki. Fuzzy Control for the Process of Heat Removal During the Composting of Agricultural Waste. *Journal of Material Cycles and Waste Management*, 16, 291-297, 2014.
- J. Rubio, D. Cruz, I. Elias, G. Ochoa, R. Balcazar, A. Aguilar. ANFIS System for Classification of Brain Signals. *Journal of Intelligent & Fuzzy Systems*, 33(3), 4033-4041, 2019.
- R Development Core Team (2018). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna - Austria.
- K. Salehi; S. Khazraee; F. Hoseini; F. Mostafazadeh. Laboratory Biogas Production from Kitchen Wastes and Applying an Adaptive Neuro Fuzzy Inference System as a Prediction Model. *INT J ENVIRON SCI TE*, 5(3), 290-293, 2014.
- P. Sefeedpari; S. Rafiee; A. Akram; K. Chau; S. H. P. Komleh. Modeling Energy Use in Dairy Cattle Farms by Applying Multi-Layered Adaptive Neuro-Fuzzy Inference System (MLANFIS). *International Journal of Dairy Science*, 10(4), 173-185, 2015.
- I. Silva; A. Silva; M. Teixeira. Modelagem Fuzzy com Técnicas de Agrupamento Fuzzy e Estruturas Neuro-Fuzzy. *C. Bra. de Sitemas Fuzzy (CBSF)*, 968-979, 2012.
- E. Soares, V. Mota, R. Poucas; D. Leite. Cloud-based Evolving Intelligent Method for Weather Time Series Prediction. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, Naples, 6p. 2017.
- S. Shahinfar; H. Yeganeh; C. Lucas; A. Kalhor; M. Kazemian; K. Weigel. Prediction of Breeding Values for Dairy Cattle Using Artificial Neural Networks and Neuro-Fuzzy Systems. *Computational and Mathematical Methods in Medicine*, 1-9, 2012.
- T. Takagi; M. Sugeno. Fuzzy Identification of Systems and Its Applications to Modeling and Control. *IEEE Trans. Syst. Man, Cybern.*, 15, 116-132, 1985.
- S. Yordanova; R. Petrova; V. Mladenov. Neuro-Fuzzy Control for Anaerobic Wastewater Treatment. *WSEAS Trans. on Systems*, 3, 724-129, 2004.
- S. Yordanova; N. Noikova; R. Petrova; P. Tzvetkov. Neuro-Fuzzy Modelling in Anaerobic Wastewater Treatment or Prediction and Control. *International Scientific Journal of computing*, 5(1), 51-56, 2006.
- S. Zareei; J. Khodaei. Modeling and Optimization of Biogas Production from Cow Manure and Maize Straw using an Adaptive Neuro-Fuzzy Inference System. *Renewable Energy*, 114, 423-427, 2017.