

NOTA BREVE

MINERAÇÃO DE DADOS PARA ESTIMATIVAS DE MORTALIDADE PRÉ-ABATE DE FRANGOS DE CORTE

DATA MINING FOR PRESLAUGHTER MORTALITY PREVIEW OF BROILERS

Rodrigues, V.C.^{1*}; Vieira, F.M.C.¹ e Silva, I.J.O.^{1A}

¹Departamento de Engenharia de Biossistemas. Piracicaba-SP. Brasil. *vcrodrig@esalq.usp.br;
^ijosilva@esalq.usp.br

PALAVRAS CHAVE ADICIONAIS

Árvores de decisão. Avicultura. Suporte à decisão.

ADDITIONAL KEYWORDS

Decision making. Decisions trees. Poultry.

RESUMO

Objetivou-se analisar a eficiência de um sistema de informação simples para diagnosticar cenários de mortalidade em condições de espera pré-abate, pelo uso de árvores de regressão e classificação, estudando dados de um abatedouro comercial de frangos de corte no Estado de São Paulo, utilizando-se um sistema de mineração de dados (CART, classification and regression trees). Esta árvore de decisão, por meio de um conjunto de dados históricos, é capaz de predizer variáveis categóricas e classificar efeitos, e apresentou 77 % de acerto e mostrou ser um meio prático e rápido para previsões, além de ser de fácil interpretação para uso direto de técnicos.

SUMMARY

The performance of a simple information system to identify possible mortality conditions in pre-slaughter operation through classification and regression trees was studied. Data referring a commercial broiler slaughterhouse, located in State of São Paulo, were studied using a data mining system (CART). This decision tree is able to predict categorical variables through a historical dataset and then classify effects. The classification tree had 77 % of success and showed to be a practical and faster way to predictions for this dataset and it is able to show an easy interpretation to direct use by the sector area experts.

INTRODUÇÃO

As operações pré-abate são um dos

maiores problemas na produção de frango de corte, devido às perdas por mortalidade antes da chegada. O sistema de criação industrial apresenta elevada densidade de animais, condições bioclimáticas inadequadas como altas temperaturas e umidade relativa do ar, na maior parte do tempo nos países de clima tropical. O tempo de viagem, a distância entre as granjas e o abatedouro e aspectos relacionados à espera no abatedouro afetam as perdas ao final do processo (Warriss *et al.*, 2005). Com base nos estudos de Vieira *et al.* (2011), foi utilizado o modelo linear generalizado duplo que considera como preditoras: temperatura externa, umidade relativa externa, tempo de espera, turno, número de aves por caixa e estação do ano. No entanto, os modelos utilizados apresentaram problemas quanto à previsão da mortalidade, abrindo espaço para o uso de sistemas especialistas. As árvores de decisão, chamadas de árvores de regressão e classificação, também são ótimas escolhas para obter resultados com precisão conhecida de forma rápida e compreensível (Sutton, 2005). Objetivou-se analisar a eficiência de um sistema de informação simples para diagnosticar possíveis condições de mortalidade em condições de espera pré-abate, através do uso de árvores de regressão e classificação.

Received: 7-6-10. Accepted: 22-9-11.

Arch. Zootec. 62 (239): 469-472. 2013.

MATERIAL E MÉTODOS

CART é um método estatístico não-paramétrico, que usa árvores de decisão para solucionar problemas de regressão e classificação. Quando a variável dependente é categórica (não contínua) CART produz uma árvore de classificação. São três os passos a serem seguidos para o crescimento da árvore de decisão (Breiman *et al.*, 1984). A árvore máxima é construída a partir do procedimento binário de regras de divisão (*split*) que ocorre na raiz da árvore onde estão todas as informações sem qualquer tipo de organização, é o chamado primeiro grupo *mãe*. Inicialmente, este grupo é dividido em dois outros grupos *filhas* segundo alguns critérios de similaridades entre as mesmas variáveis de um grupo e cada *filha* torna-se *mãe* para que o processo ocorra até que cada uma das divisões (regras *if-then*) descreva respostas homogêneas quanto a variável categórica. Para que isto aconteça o crescimento da árvore é feito por meio de um descritor apropriado. O sistema CART usa um algoritmo cujo critério de divisão é apresentar a máxima redução de impureza dos dados em cada grupo, ou seja, grupos homogêneos de informações em cada ramo da árvore. Para tanto é utilizado o índice Gini (Breiman *et al.*, 1984) que é a medida de dispersão dos dados presentes dos nós da árvore e é comumente usado para variáveis categóricas.

O produto das probabilidades mede justamente a probabilidade de erro entre as classes. Obtidos os atributos que constituirão a construção da árvore, a árvore máxima é obtida, e o processo de *poda* (*pruning*) é necessário devido à ocorrência de ambigüidades (*overfitting*). Durante este processo, árvores menores e menos complexas são obtidas por cortes sucessivos dos ramos da árvore (regras) máxima. As diferentes subárvore são comparadas entre si para que a melhor seja encontrada. O critério para seleção é o custo que cada subárvore representa. A medida é feita com relação ao

parâmetro complexidade do custo ($R_d(T)$), para a árvore T.

Durante o processo de *poda* este parâmetro varia de 0 a 1 o que minimiza o valor de $R_d(T)$ reduzindo o custo de treinamento do modelo. A seleção da melhor árvore é feita com base em informações do menor custo de complexidade da validação cruzada que testa o desempenho do modelo, analisando uma parcela retirada dos dados em relação aos dados de referência. É calculado, para tanto, a estimativa de erro de classificação (*resubstitution error*), ou seja, a proporção de observações originais que foram erroneamente classificadas em vários subgrupos da árvore original. A validação cruzada é utilizada para estimar o verdadeiro erro, para as árvores de vários tamanhos. A árvore que apresenta menor erro de validação cruzada é escolhida. Após a escolha, é possível calcular o custo estimado a partir da análise discriminante e verificar a matriz de classificação dos dados originais. O conjunto de dados foi obtido por meio de um experimento realizado em um abatedouro no Estado de São Paulo, Brasil, para 218 carregamentos de frangos de corte (Vieira *et al.*, 2010). Foram analisados os caminhões de transporte sob a condição de espera, em cada período estudado (manhã, tarde e noite). Dessa forma, considerou-se para a análise dos dados 4 repetições para o turno da manhã, 5 para o turno da tarde e 5 para o turno da noite.

O modelo de árvore de regressão foi construído a partir do *Matlab Statistics toolbox® R2006a*. Foram utilizadas 4 classes para representar a taxa de mortalidade, de forma categórica, conforme Silva e Vieira (2010).

RESULTADOS E DISCUSSÃO

A melhor árvore, que apresenta o menor valor de variância residual (0,57), foi escolhida pelo sistema e apresenta 13 folhas (nós terminais), sendo que a árvore máxima apresentou 35 folhas devido sua tamanho

MINERAÇÃO DE DADOS E MORTALIDADE DE FRANGOS DE CORTE

complexidade (**figura 1**).

Pela formação da árvore, é possível afirmar que o sistema reconheceu como variável de melhor retratação dos grupos o turno de viagem, pois o algoritmo conseguiu separar dois grupos bem delimitados. Partindo do nó do topo da árvore, também chamado de raiz, foi possível observar que para o turno 1 (manhã) o suporte de decisão é dado pelo ramo esquerdo da árvore. Dessa forma, a interpretação do sistema de suporte à decisão mostra que a variável turno foi selecionada como de maior ganho (índice Gini) para dar suporte às demais informações, dessa forma, para os turnos 1 e 2, as informações estão contidas na ramificação esquerda da árvore, onde maiores detalhes são mostrados para a necessária separação das classes. Para o turno 3, ou seja, noturno, a ordem das variáveis preditoras mostrou-se diferentes quando comparadas aos turnos 1 e 2.

Dessa forma, o desempenho preditivo da árvore de classificação foi de 77 %. Foram

167 conjuntos de dados classificados adequadamente. A classe que apresentou problemas de perdas de classificação (*miscalclassification*) foi a *inaceitável* por ter apresentado poucos conjuntos de treino (11) em comparação aos demais.

O sistema de suporte à decisão mostra que se o turno avaliado for manhã, por exemplo, o ramo da árvore a ser utilizado pela análise de previsão será o da esquerda, pois o turno de número 1 (manhã) foi selecionado. Assim, prosseguindo a análise, tem-se que para distâncias percorridas inferiores a 11,5 km (*galho* à esquerda do ramo esquerdo) a taxa de mortalidade esperada é classificada como ideal, caso a distância seja igual ou superior a 11,5 km, outros critérios devem ser tomados como orientação para se predizer as possíveis classificações das taxas de mortalidade. Nesse caso, se a umidade relativa do ar for menor que 50,5 % o *galho* a ser utilizado é do da esquerda e assim sucessivamente.

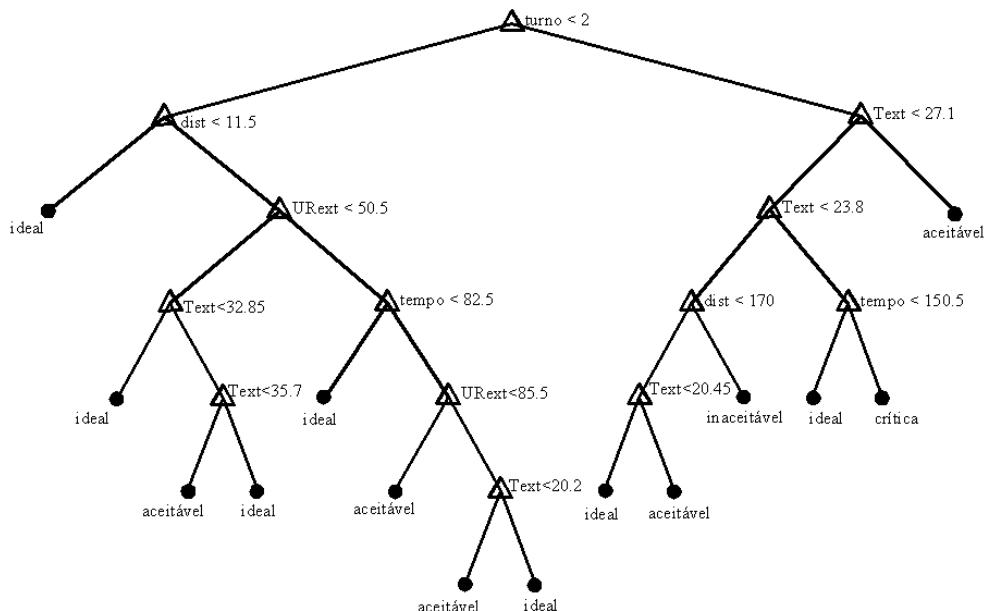


Figura 1. Representação gráfica da melhor árvore de classificação para os 218 conjuntos de dados analisados. (Graphic representation of best decision tree for 218 analyzed dataset).

RODRIGUES, VIEIRA E SILVA

Tais resultados acima foram confirmados anteriormente por diversos trabalhos que envolveram as operações pré-abate de frangos de corte, especialmente às de transporte e espera em abatedouro. Quanto ao turno em que as operações foram executadas, Barbosa Filho *et al.* (2009) encontraram que o melhor turno sob o ponto de vista bioclimático é o turno da manhã, por oferecer as melhores condições térmicas para o transporte de aves. Isto explica o resultado de melhor ganho do turno 1 (manhã) segundo o índice Gini. Juntamente com as demais informações, este turno ofereceu melhores opções para a tomada de decisão. Com relação à distância, também a árvore obteve resultados similares e concordantes com Vecerek *et al.* (2006), os quais recomendaram que as menores distâncias são melhores e com baixas mortalidades associadas às distâncias abaixo de 50 km. No entanto, considerando a realidade da maioria das empresas, cujas granjas integradas se encontram em um raio acima de 11,5 km, como foi evidenciada na CART, outros fatores passam a ser importantes para a tomada de decisão, como por exemplo, o tempo de espera.

BIBLIOGRAFIA

- Barbosa Filho, J.A.D.; Vieira, F.M.C.; Silva, I.J.O.; Garcia, D.B.; Silva, M.A.N. e Fonseca, B.H.F. 2009. Transporte de frangos: caracterização do microclima na carga durante o inverno. *Rev Bras Zootecn*, 38: 2442-2446.
- Breiman, L.; Friedman, J.H.; Olshen, R.A. and Stone, C.J. 1984. Classification and Regression Trees. Wadsworth. Pacific Grove. 368 pp.
- Silva, I.J.O. e Vieira, F.M.C. 2010. Ambiência animal e as perdas produtivas no manejo pré-abate: o caso da avicultura de corte brasileira. *Arch Zootec*, 59: 113-131.
- Sutton, C.D. 2005. Handbook of Statistics. Penn State University. Pennsylvania. 24: 303-329.
- Vecerek, V.; Grbalova, S.; Voslarová, E.; Janácková, B. and Malena, M. 2006. Effects of travel distance and the season of the year on death rates of broilers transported to poultry processing plants. *Poultry Sci*, 85: 1881-1884.
- Vieira, F.M.C.; Silva, I.J.O.; Barbosa Filho, J.A.D. and Vieira, A.M.C. 2010. Productive losses on broiler preslaughter operations: effect of the distance from farms to abattoirs and of lairage time in a climatized holding area. *Rev Bras Zootecn*, 39: 2471-2476.
- Vieira, F.M.C.; Silva, I.J.O.; Barbosa Filho, J.A.D.; Vieira, A.M.C.; Rodrigues-Sarnighausen, V.C. and Garcia, D.B. 2011. Thermal stress related with mortality rates on broiler's preslaughter operations: a lairage time effect study. *Ciênc Rural*, 41: 1639-1644.
- Warriss, P.D., Pagazaurtundua, A. and Brown, S.N. 2005. Relationship between maximum daily temperature and mortality of broiler chickens during transport and lairage. *Brit Poultry Sci*, 46: 6647-6651.

O tempo de espera pré-abate só é eficaz se realizado dentro de galpões climatizados com nebulização e climatização (Silva e Vieira, 2010). Considerando a relação entre o tempo de espera e a distância, foi evidenciado por meio da árvore de decisão que para distâncias acima de 11,5 km e umidade relativa do ar acima de 50,5 %, o tempo de espera estimado pela CART visando o nível ideal de mortalidade foi abaixo de 82,5 minutos.

A árvore de decisão é uma plataforma de fácil compreensão a partir de um conhecimento introdutório, o que viabiliza o uso desse sistema para possíveis aferições de produtores que estejam interessados em simular algumas condições de campo.

CONCLUSÕES

O sistema de suporte à decisão mostrou-se eficiente e de fácil análise. Para o aumento da performance do sistema outros algoritmos deverão ser empregados para que o acerto ultrapasse os 77 % atingido. Deve-se considerar que a ferramenta apresentada tem grande utilidade na produção animal como novo instrumento de avaliação de dados reais e históricos de produção.