

Modelagem Computacional de Indicadores Metabólicos para Estudo de Eficiência Reprodutiva em Vacas de Corte

*Sandro da Silva Camargo¹, Rodrigo Carneiro Campos de Azambuja², Josiane de Oliveira Feijó²,
Marcio Nunes Corrêa², Augusto Schneider², Fernando Flores Cardoso³,*

¹Campus Bagé – Universidade Federal do Pampa (UNIPAMPA) – Bagé, RS

²Núcleo de Pesquisa, Ensino e Extensão em Pecuária (NUPEEC)
Universidade Federal de Pelotas (UFPEL) – Pelotas, RS

³Centro de Pesquisa de Pecuária dos Campos Sul-Brasileiros (CPPSUL)
Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) – Bagé, RS

RESUMO

Atualmente, a pecuária ocupa lugar de destaque na economia brasileira. Dada esta importância, a fim de se atingir um maior sucesso na produção de bovinos de corte, um dos fatores que tem sido explorado é o melhor aproveitamento da capacidade reprodutiva das vacas. Porém, este aproveitamento é limitado pela falta de uma compreensão clara de como as concentrações de elementos hormonais e metabólicos interagem no organismo bovino e influenciam na eficiência reprodutiva. Neste contexto, o presente trabalho visa a aplicação de técnicas de inteligência computacional para identificar padrões descritivos sobre o comportamento de hormônios e metabólitos a fim de criar modelos descritivos e preditivos que possam aumentar a compreensão sobre a eficiência reprodutiva bovina. Os resultados obtidos mostram que o hormônio Fator de Crescimento similar à Insulina tipo 1 (IGF-I) pode ser utilizado para prever a propensão da vaca a ter um diagnóstico de prenhez no ano seguinte. É esperado que tais modelos possam ser utilizados para contribuir no aumento da eficiência reprodutiva de vacas de corte.

PALAVRAS-CHAVE: Inteligência Computacional, Indicadores Metabólicos, Fator de Crescimento Similar à Insulina Tipo 1.

ABSTRACT

Nowadays, livestock farming occupies a prominent place in the Brazilian economy. Hence, in order to achieve greater success in production of beef cattle, one factor which has been explored is the best use of reproductive performance of cows. However, this use is limited by the lack of a clear understanding of how concentrations of hormonal and metabolic elements interact in

bovine body, and how they influence reproductive efficiency. In this scope, this paper aims to apply computational intelligence techniques towards identifying descriptive patterns regarding behavior of hormones and metabolites in order to creating descriptive and predictive models which can increase understanding of bovine reproductive efficiency. Our results show that the Insulin-Like Growth Factor type 1 (IGF-I) can be used in order to predict the propensity of cows having a positive pregnancy diagnostic in the following year. We expect our models may be used to contribute for increasing of reproductive efficiency of beef cows.

KEYWORDS: Computational Intelligence, Metabolic Indicators, Insuline-like Growth Factor 1.

INTRODUÇÃO

O Brasil possui o maior rebanho bovino do mundo, totalizando em torno de 212 milhões de cabeças, das quais, aproximadamente, 160 milhões são destinadas à produção de carne (IBGE, 2012). A aptidão do país para a pecuária é favorecida, principalmente, pela disponibilidade de grandes áreas de pastagens, pelo clima favorável e, mais recentemente, pela profissionalização da cadeia produtiva da carne.

A fim de manter o país em uma posição de destaque no cenário mundial, tem sido introduzidos na pecuária vários programas de melhoramento animal, os quais são baseados, principalmente, em métodos de seleção e/ou cruzamentos. A utilização destes métodos busca um melhor desempenho nos indicadores de importância econômica, tornando possível a produção de animais mais adaptados aos diferentes ambientes (GREGORY; CUNDIFF, 1980). A fim de se atingir um maior sucesso na produção de bovinos de corte um dos fatores que tem sido explorado é o melhor aproveitamento da capacidade reprodutiva das vacas (YAVAS; WALTON, 2000).

Dentre as características produtivas importantes para uma vaca está a capacidade de produção de leite em quantidade adequada ao crescimento do seu bezerro (CROMBERG; COSTA, 1997). Dado que a lactação é um estado dominante sobre outras atividades fisiológicas, a vaca prioriza a produção de leite para o bezerro em detrimento da atividade reprodutiva (BAUMAN, 2000). Este padrão metabólico é clássico em vacas leiteiras, onde a alta produção de leite, em parte, só é possível de ser obtida através da utilização de parte da reserva de gordura corporal para obtenção de energia e gordura para a síntese de leite na glândula mamária. Este evento homeorrético resulta em um Balanço Energético Negativo (BEN), típico da fase inicial de lactação (BUTLER, 2003). A severidade do BEN pode estar relacionada à adaptabilidade da raça ao meio ambiente e, desta forma, as vacas de grupos genéticos mais adaptados às condições do ambiente podem apresentar um melhor desempenho produtivo.

Transtornos metabólicos também tem relação com o BEN. Diversos eventos hormonais e metabólicos estão envolvidos nesta condição, determinados, principalmente, pelas drásticas mudanças na ingestão de matéria seca e pela transição da condição fisiológica da vaca, de gestante à lactante (GRUMMER, 1993). Apesar da importância destes processos na eficiência reprodutiva das vacas de corte, eles ainda não são entendidos em sua plenitude.

Dentro deste escopo, a complexidade inerente a todos estes processos biológicos dificulta sua plena compreensão, principalmente se for utilizada uma abordagem holística baseada na análise de grandes quantidades de dados, seja por especialistas de domínio humanos, seja por técnicas estatísticas convencionais. Por outro lado, nos dias atuais, um dos grandes impulsos para o desenvolvimento da computação é o projeto de modelos algorítmicos com a finalidade de tratar problemas de análise de dados incrementalmente complexos(ENGELBRECHT, 2007). Como consequência deste desenvolvimento, a literatura tem relatado muitos casos de sucesso através da modelagem de inteligência biológica e natural, nas mais variadas áreas de conhecimento, resultando no que se convencionou chamar de "Sistemas Inteligentes".

Como exemplos bem sucedidos da aplicação de sistemas inteligentes em problemas da área biológica, para análise de grandes quantidades de dados, pode ser citada a aplicação de redes neurais para detectar padrões de alterações metabólicas envolvidas na ocorrência de mastite (CAMPOS et al., 2006). Outro exemplo é a utilização técnicas de clustering para identificar os genes diferencialmente expressos em laranjas infectadas por duas bactérias diferentes (BRETON et al., 2014). As mesmas técnicas foram utilizadas com sucesso para identificar genes com níveis de expressão similares em diferentes espécies de eucalipto, sob diferentes condições ambientais (OLIVEIRA et al., 2011). Abordagens inteligentes baseadas em regras de associação também foram utilizados com sucesso para modelar a especificidade da Protease do Vírus HIV-1 (CAMARGO; ENGEL, 2006). (KECMAN, 2001; KONAR, 2000) apresentam outras abordagens e aplicações de inteligência computacional.

Neste contexto, o objetivo deste trabalho é, através de uma abordagem reducionista, aplicar técnicas de inteligência computacional para modelar o comportamento de indicadores metabólicos durante o período de transição gestante/lactante e suas relações com a habilidade materna e eficiência reprodutiva em vacas de corte de diferentes genótipos criadas no sul do Brasil.

MATERIAL E MÉTODOS

Para este trabalho foram utilizados dados de 32 vacas de primeira, segunda e terceira crias, com idades entre três e cinco anos, sob pastoreio contínuo, com carga animal média de 315 kg/ha, catalogadas no estudo de (AZAMBUJA, 2013). As vacas são oriundas de um experimento de cruzamentos que foi conduzido entre 2006 e 2009 no Centro de Pesquisa Pecuária dos Campos Sul-Brasileiros, Embrapa Pecuária Sul. Para o presente estudo foram utilizadas vacas de quatro composições raciais, sendo elas:

- sete animais da raça Angus (ANAN),
- nove do cruzamento de vacas Angus com touros Nelore (ANNE),
- oito do cruzamento de vacas Nelore com touros Angus (NEAN), e
- oito da raça Nelore (NENE).

Coleta de Dados

Para cada uma das vacas disponíveis para o experimento, foram coletados os seguintes dados: peso, escore de condição corporal (ECC), hormônios fator de crescimento semelhante à Insulina

Inteligência Computacional e Árvores de Decisão

A Inteligência Computacional (IC) pode ser conceituada como o ramo da ciência da computação que se preocupa com a automatização do comportamento inteligente. Atualmente, a área de IC engloba uma ampla variedade de sub-campos, dentre eles, uma das mais férteis áreas de pesquisa é o que se preocupa com a construção de sistemas de alto desempenho capazes de aprender através da experiência e obter conhecimento a partir de dados (CAMARGO, 2010).

Segundo (KONAR, 2000), há quatro diferentes classes de aprendizado de máquina: aprendizado supervisionado, aprendizado não supervisionado, aprendizado por reforço e aprendizado por programação em lógica indutiva. No presente trabalho, foram aplicadas as técnicas de aprendizado supervisionado, que referem-se a uma classe de algoritmos que visam aprender um relacionamento entre dados de entradas e dados de saída. Este relacionamento geralmente descreve uma dependência ou função $f_o(x)$ presente de forma implícita em um conjunto de treinamento $D = [x(i), y(i)] \in \mathfrak{R}x\mathfrak{R}, i = 1, \dots, l$ consistindo de l pares $(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)$. As entradas x consistem em um vetor n -dimensional onde $x \in \mathfrak{R}$, e as saídas y consistem em um vetor 1-dimensional onde $y \in \mathfrak{R}$. Dependendo do valor a ser predito o aprendizado supervisionado pode ser de dois tipos: regressão quando os valores de saída são contínuos, e classificação quando os valores de saída são discretos (KECMAN, 2001). Durante o processo de treinamento, as amostras são sucessivamente submetidas ao algoritmo de aprendizado. Para cada amostra de entrada, o algoritmo tenta prever a saída. A saída predita pelo algoritmo é comparada com a saída real, a diferença entre elas é utilizada para reajustar os parâmetros do modelo. Desta forma, o algoritmo iterativamente ajusta seus parâmetros para criar um modelo que faça um mapeamento das entradas para a saída. Após o processo de aprendizado supervisionado, é criado um modelo que pode ser utilizado para simular o conhecimento do especialista do domínio.

Neste trabalho, foram aplicadas as técnicas de classificação, que estão inseridas no escopo do aprendizado supervisionado. Foi priorizada a construção de modelos do tipo caixa branca, onde se enquadram os algoritmos de geração de regras ou árvores de decisão. Apesar destes modelos serem lineares e, tipicamente, terem uma capacidade preditiva menor que modelos não lineares, sua maior vantagem é a geração de modelos interpretáveis (CAMARGO, 2002). Na fase de avaliação dos modelos foi utilizada a técnica *10-fold cross validation* para assegurar a correta mensuração da capacidade preditiva dos modelos. Esta técnica é particularmente útil quando o conjunto de dados de treinamento é pequeno, ou quando a quantidade de parâmetros do modelo é grande (KOHAVI, 1995).

O algoritmo de geração de árvores utilizado foi o *J48* (QUINLAN, 1993). Este algoritmo classifica instâncias ordenando-as da raiz da árvore em direção a suas folhas. As características mais relevantes posicionam-se mais perto da raiz da árvore. À medida que a relevância da característica diminui, esta característica é posicionada mais longe da raiz e mais próxima às folhas (MITCHELL, 1997).

Para qualquer problema de classificação, podem ser geradas diversas árvores de decisão que o explicam. Cada árvore possui um nível de complexidade, diretamente proporcional à


sua quantidade de nodos, e um nível de precisão, diretamente proporcional à quantidade de instâncias que são corretamente classificadas. De acordo com o princípio científico do reducionismo (SCOTT, 2004), havendo diversas explicações aceitas para um determinado fenômeno, aquelas mais complexas devem ser preteridas em favor das mais simples, que são mais facilmente verificáveis. Este princípio também é conhecido por lei da parcimônia ou navalha de Occam (ORESQUES; SHRADER-FRECHETTE; BELITZ, 1994).

RESULTADOS E DISCUSSÃO

Sobre os dados apresentados nas tabelas 1 e 2, para cada uma das 32 amostras, foi aplicado o algoritmo de classificação *J48*. O objetivo deste experimento foi criar modelos preditivos para o diagnóstico de prenhez da vaca no ano seguinte a partir dos dados de entrada. Foram encontrados diversos padrões de comportamento dos metabólitos que influenciam tal diagnóstico. A seguir são apresentados os dois padrões mais relevantes, dado o grau de acerto das árvores de decisão.

A figura 1 mostra a árvore de decisão criada pelo algoritmo *J48* para prever qual será o diagnóstico da vaca, se *prenga* ou *vazia*, no ano seguinte. Esta árvore mostra que o nível de IGFI42, que representa o hormônio IGF-I medido no 42º dia pós-parto, é o indicador mais importante para a predição do diagnóstico no ano seguinte. O ramo inferior da árvore mostra que, caso o nível de IGFI42 seja igual ou inferior a 77,03 o diagnóstico da vaca será *vazia*. Já o ramo superior, mostra que no caso de IGFI42 seja superior ao limiar de 77,03, a predição do diagnóstico passa pela análise do nível do indicador IGFI28, que representa o hormônio IGF-I medido no 28º dia pós-parto. Caso este indicador tenha valor igual ou inferior a 50, o diagnóstico também será *vazia*. Caso os dois indicadores tenham valores superiores aos limiares mencionados, o diagnóstico será *prenga*.

Figura 1: Árvore de Decisão IGF-I gerada pelo algoritmo *J48*




Fonte: Próprio autor

A figura 2 mostra a superfície de decisão com as amostras utilizadas. Os símbolos em azul mostram as vacas prenhas e os símbolos em vermelho, as vacas vazias. São utilizados símbolos diferentes para denotar as diferentes raças utilizadas no experimento. As linhas verdes indicam os limiares apontados pela árvore de decisão. O gráfico mostra que todas as vacas, com nível de IGFI42 igual ou inferior ao limiar de 77,03, estão com diagnóstico *vazia*. Desta forma, esta

regra tem 100% de precisão. A regra que indica nível de IGFI42 igual ou inferior a 77,03 e nível de IGFI28 igual ou inferior a 50, indica uma vaca com diagnóstico *vazia*. Esta regra tem um erro em cinco amostras, representando 20% de erro. A última regra, apontando nível de IGFI42 superior a 77,03 e nível de IGFI28 superior a 50, indica que a vaca deverá ter diagnóstico *preanha*. Esta regra tem dois erros em 15 amostras, apresentando 13% de erro.


Figura 2: Representação espacial da árvore de decisão



Fonte: Próprio autor

Para corroborar com os resultados apresentados acima, foram analisados os níveis médios de Fator de Crescimento Similar à Insulina tipo 1 (IGF-I) nas vacas prenhas e vazias. A figura 3 mostra que enquanto as vacas prenhas apresentam um crescimento de produção do IGF-I após o parto, as vacas vazias apresentam uma diminuição da produção deste hormônio.

Figura 3: Diferença de produção do Fator de Crescimento Similar à Insulina tipo 1 (IGF-I) em vacas prenhas e vazias.



Fonte: Próprio autor

Em resumo, a árvore apresentada na figura 1 apresenta 3 erros de classificação em 32

amostras, representando mais de 90% de acerto. Desta forma, conclui-se que o nível do hormônio Fator de Crescimento similar à Insulina tipo 1, medido nos 42º e 28º dias pós-parto, é determinante para predição do estado de prenhez no ano seguinte, podendo ser tomado como parâmetro para seleção das vacas serão descartadas, e tornando possível um incremento da eficiência reprodutiva do lote analisado.

A existência de apenas dois indicadores no modelo criado com o algoritmo J48 não significa que os demais dados e indicadores, apresentados nas tabelas 1 e 2, não tenham influência na eficiência reprodutiva. Isto significa que a adição de outros indicadores no modelo não gera um aumento relevante na sua capacidade preditiva. Desta forma, de acordo com a lei da parcimônia (ORESQUES; SHRADER-FRECHETTE; BELITZ, 1994), o modelo mais simples foi o preferido.

CONCLUSÕES

Este trabalho demonstrou que é viável a utilização de técnicas de inteligência computacional para predição de eficiência reprodutiva em vacas de corte, a partir de dados de metabólitos e hormônios. Os modelos computacionais aqui criados, através da técnica de árvores de decisão, mostraram que o hormônio Fator de Crescimento similar à Insulina tipo 1 (IGF-I) pode ser utilizado para prever a propensão da vaca a ter um diagnóstico de prenhez no ano seguinte.

Assim, com a utilização dos resultados aqui apresentados, é possível a obtenção de subsídios para selecionar as vacas de descarte e, desta forma, contribuir para um incremento da eficiência reprodutiva de vacas de corte.

Apesar da pequena quantidade de amostras utilizadas para o experimento, a aplicação de técnicas de validação cruzada assegura uma mensuração apropriada da capacidade preditiva dos modelos aqui criados. Por outro lado, dentre os trabalhos futuros, pretende-se expandir o número de animais estudados, e também para outros lotes englobando outras raças, a fim de comprovar a generalidade dos resultados aqui obtidos.

AGRADECIMENTOS

A CAPES e ao CNPq pelo fornecimento dos recursos para o projeto de pesquisa “Avaliação da eficiência produtiva de vacas de corte puras e oriundas de cruzamentos envolvendo as raças Angus, Hereford, Caracu e Nelore no sul do Brasil” (Processo 478699/2010-7).

REFERÊNCIAS

AZAMBUJA, R. C. C. de. Características metabólicas do período de transição e eficiência produtiva de vacas de corte de diferentes genótipos criadas no sul do Brasil. *Universidade Federal de Pelotas (Dissertação de Mestrado)*, 2013.

BAUMAN, D. E. Regulation of nutrient partitioning during lactation: homeostasis and homeostasis. In: CRONJÉ, P. B. (Ed.). *Ruminant physiology. Digestion, metabolism, growth and reproduction*. Wallingford: CAB, 2000. p. 311–328.

- BRETON, M. C. et al. Identification of differentially expressed genes in citrus sinensis leaves and branches in response to candidatus liberibacter asiaticus and ca. l. americanus. *Journal of Citrus Pathology*, v. 1, p. 269–269, 2014.
- BUTLER, W. R. Energy balance relationships with follicular development, ovulation and fertility in postpartum dairy cows. *Livestock Production Science*, v. 83, p. 211–218, 2003.
- CAMARGO, S. S. Mineração de regras de associação no problema da cesta de compras aplicada ao comércio varejista de confecção. *Universidade Federal do Rio Grande do Sul (Dissertação de Mestrado)*, 2002.
- CAMARGO, S. S. Um modelo neural de aprimoramento progressivo para redução de dimensionalidade. *Universidade Federal do Rio Grande do Sul (Tese de Doutorado)*, 2010.
- CAMARGO, S. S.; ENGEL, P. M. Mining association rules for hiv-1 protease cleavage site prediction. In: *Anais do V Simpósio Brasileiro de Qualidade de Software*. [S.l.: s.n.], 2006. p. 105–112.
- CAMPOS, R. et al. Uma abordagem neural para predição da mastite a partir de indicadores bioquímicos do metabolismo. In: *II Congresso Brasileiro de Qualidade do Leite*. [S.l.: s.n.], 2006.
- CROMBERG, V. U.; COSTA, M. J. R. P. da. Mamando logo, para crescer a receita. In: *ANUALPEC*. São Paulo, SP: FNP, 1997. (ANUALPEC'97), p. 215–217.
- ENGELBRECHT, A. P. *Computational Intelligence: An introduction*. 2. ed. Chichester: John Wiley & Sons, 2007.
- GREGORY, K. E.; CUNDIFF, L. V. Crossbreeding in beef cattle: evaluation of systems. *Journal of Animal Science*, v. 51, p. 1224–1242, 1980.
- GRUMMER, R. R. Etiology of lipid-related metabolic disorders in periparturient dairy cows. *Journal of Dairy Science*, v. 76, p. 3882–3896, 1993.
- IBGE, I. B. de Geografia e E. *Produção Pecuária Municipal 2012*. [S.l.], 2012. Disponível em: <<http://www.ibge.gov.br/home/estatistica/economia/ppm/2011/default.sht>>.
- KECMAN, V. *Learning and Soft Computing: support vector machines, neural networks, and fuzzy logic models*. Cambridge: MIT Press, 2001.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence*. [S.l.: s.n.], 1995.
- KONAR, A. *Artificial Intelligence and Soft Computing: behavioral and cognitive modeling of the human brain*. Boca Raton: CRC Press, 2000.
- MITCHELL, T. M. *Machine Learning*. New York: McGraw-Hill, 1997.

OLIVEIRA, L. A. de et al. Reference genes for the normalization of gene expression in eucalyptus species. *Plant and Cell Physiology*, v. 53, p. 405–422, 2011.

ORESQUES, N.; SHRADER-FRECHETTE, K.; BELITZ, K. Verification, validation, and confirmation of numerical models in the earth sciences. *Science Magazine*, v. 5147, p. 641–646, 1994.

QUINLAN, J. R. *C4.5: Programs for Machine Learning*. New York: Morgan Kaufmann Publishers, 1993.

SCOTT, A. Reductionism revisited. *Journal of Consciousness Studies*, v. 11, n. 2, p. 51–68, 2004.

YAVAS, Y.; WALTON, J. S. Postpartum acyclicity in suckledbeef cows: a review. *Theriogenology*, v. 54, p. 25–55, 2000.