


Processamento de dados e suporte para tomada de decisão na pecuária leiteira de precisão



bigstockphoto.com

Luigi Francis Lima Cavalcanti¹ - CRMV-MG 10610

Marcelo Neves Ribas² - CRMV-MG 8208

Luiz Gustavo Ribeiro Pereira³ - CRMV-MG5930

¹ Médico Veterinário, Doutor em Zootecnia, Bolsista CNPq – RHAE, Projeto Intergado/Seva (luigi.cavalcanti@intergado.com.br) – CRMV-MG: 10610

² Médico Veterinário, Doutor em Zootecnia, Bolsista CNPq – RHAE Seva Engenharia, Diretor-Executivo Intergado Tecnologia (marcelo@intergado.com.br) – CRMV-MG: 8208

³ Médico Veterinário, Doutor em Ciência Animal, Pesquisador da Embrapa Gado de Leite (luiz.gustavo@embrapa.br) – CRMV-MG: 1000

1. Introdução

A pecuária de precisão baseia-se intrinsecamente na coleta de dados de modo refinado, com maior frequência e de forma automatizada. Esse processo intenso tem como conse-

A pecuária de precisão baseia-se intrinsecamente na coleta de dados de modo refinado, com maior frequência e de forma automatizada.

quência imediata a geração de bancos de dados que devem ser interpretados eficien-

temente com o intuito de prover aos usuários suporte para tomadas de decisão. Caso esse objetivo final (i.e., embasar tomadas de decisão) não se torne possível, corre-se o risco de in-

validar ou tornar obsoletas todas as etapas anteriores e, dessa forma, todo o esforço despendido desde a identificação do problema, passando por desenvolvimento de sensores e algoritmos que consigam monitorá-lo, até a geração da informação em si podem ter sido em vão. Embora esse objetivo seja claro, alcançá-lo não é tarefa simples e implica

custo associado a investimento em tempo, experimentação, desenvolvimento e aplicação de tecnologias e recursos humanos qualificados.

Rutten *et al.* (2013) revisaram 126 trabalhos publicados e encontraram relatos de utilização de 139 dispositivos para monitoramento do manejo sanitário em sistemas leiteiros, mas nenhum atingiu o objetivo final de aconselhar o fazendeiro ou técnico em suas decisões, ou mesmo integrar as leituras dos dispositivos de forma a gerar informações capazes de dar suporte a decisões, tendo os autores concluído que muito se tem feito para o desenvolvimento de dispositivos, mas pouco tem sido aplicado para de fato auxiliar no manejo dos animais. Esse cenário é coerente com um questionário realizado em fazendas no estado do Kentucky, EUA, onde 35% dos respondentes concordaram que o excesso e o não saber lidar com a informação contribuíram como causas da lenta adoção de tecnologias de pecuária de precisão (Bewley e Russel, 2010).

Esta revisão tem como o objetivo descrever de forma generalizada, independentemente do tipo de sensor ou utilidade de dispositivos, as etapas consecutivas à coleta de dados, caracterizando o desenvolvi-

O advento do fenômeno conhecido como “internet das coisas” resultou em uma geração exponencial de dados, consequência da popularização de dispositivos capazes de gerá-los tais quais celulares, computadores domésticos, ferramentas de empresas e objetos em um estoque.

to de algoritmos, processamento dos dados, e geração de informações que darão suporte para tomada de decisão.

2. Geração e coleta de dados

O advento do fenômeno conhecido como “internet das coisas” resultou em uma geração exponencial de

dados, consequência da popularização de dispositivos capazes de gerá-los tais quais celulares, computadores domésticos, ferramentas de empresas e objetos em um estoque. Esse excesso de informação demanda grande habilidade de pesquisadores e cientistas para que se consiga extrair informação útil. Esse recurso humano deve ser dotado de habilidades da área de estatística, mas também da área da origem do problema que está sendo debatido. Em alguns momentos, a distância entre essas duas áreas se torna tão grande que se faz premente a formação de equipes interdisciplinares para que se crie a solução ideal.

No âmbito do agronegócio, a entrada de dispositivos desse tipo se tornou popular primeiramente no meio agrícola, com a entrada de sensores capazes de comunicar com o Sistema de Posicionamento Global (GPS) e a implementação de *software* habilitados com ferramentas de georreferenciamento. Esse tipo de mapeamento digital em tempo real garante aos seus usuários a capacidade de identificar eficientemente cada gleba de terra e, portanto, subdividir custos, receitas e tomadas de decisão conforme a performance de cada setor da propriedade. Esse processo de individualização, a base da agricultura de precisão, permite ações como aplicações específicas tanto quantitativa quanto qualitativamente

de adubos e pesticidas, uso mais eficiente de implementos, entre outros quesitos que antes seriam utilizados de forma mais generalista. Esse tipo de ação fomenta, entre outras vantagens, a uniformidade da produção e efeitos colaterais positivos, como o direcionamento do uso de herbicidas apenas em regiões de maior demanda, reduzindo custos diretos e indiretos, como o impacto ambiental dos resíduos do mesmo.

Seguindo a mesma tendência, algumas tecnologias de pecuária de precisão passaram a ser adotadas corriqueiramente por fazendas leiteiras brasileiras: ordenhadeiras mecânicas que registram produção e condutividade elétrica do leite produzido pelos animais, balanças de passagem que estimam o peso vivo dos animais bem como as variações de peso ao longo do tempo e sensores de atividades que, a partir da contagem de passos, detectam animais em estro. Outras tecnologias de precisão estão sendo desenvolvidas e avaliadas em centros de pesquisa e precisam de um maior tempo de maturação para que sejam adotadas em propriedades comerciais, como sensores que registram consumo de alimentos e água, comportamento alimentar, frequência cardíaca e respiratória, temperatura corporal, pH ruminal, atividade e posição dos animais, entre outros.

3. Extração do conhecimento

O aumento exponencial de dados coletados automaticamente por dispositivos eletrônicos nas atividades agropecuárias traz como consequência direta a geração de grandes conjuntos de dados. Para que essa coleta tenha significado, a massa de dados

deverá ser cuidadosamente analisada e interpretada para que se chegue à informação de interesse.

Vários autores tentaram formalizar esse processo de interpretação por meio de esquemas e teorias. Destaca-se dentre estes o fluxograma denominado Extração do Conhecimento (do inglês, *Knowledge Discovery in Database* ou *KDD*). Embora esse termo tenha se tornado mais corriqueiro nos últimos anos, seu conceito foi formalizado no final da década de 1980 e baseia-se em um processo de várias etapas, não trivial, iterativo e interativo, para a identificação de padrões compreensíveis, válidos, novos e potencialmente úteis a partir de grandes conjuntos de dados (Fayyad *et al.*, 1996).

Para que essa coleta [de dados] tenha significado, a massa de dados deverá ser cuidadosamente analisada e interpretada para que se chegue à informação de interesse.

A designação “não trivial” implica que o processo de KDD é passível de inferência, e isso revela que essa metodologia é dependente da capacidade do analista em interpretar o fenômeno, ou seja, não se baseia somente em cálculo de médias ou desvios padrão.

O termo “iterativo” denota que o processo como um todo é passível de repetição e ensaios do tipo tentativa e erro, ou seja, demanda que o executor avalie o problema por várias óticas, aplicando diferentes técnicas ou algoritmos quantas vezes preciso for para que se atenda ao objetivo primordial com acurácia e precisão.

O diagrama apresentado na Figura 1 resume as etapas do KDD. Como pode ser observado, a primeira etapa consiste em retirar do banco de dados os fragmentos ou *subsets* de interesse. No caso da pecuária de precisão, essa etapa é crucial, pois favorecerá o processo de integração dos dados brutos. Isso porque é muito comum que dados sejam coleta-




Figura 1. Diagrama de formalização do processo de extração de conhecimento, do inglês, *Knowledge Discovery from Database*. Adaptado de Fayyad et al. (1996).

dos por diferentes dispositivos, e muitas vezes esses sensores são produzidos por diferentes fabricantes. Nesse sentido, a seleção passa a ser essencial, uma vez que cada dispositivo irá retornar diferentes arquivos, com diferentes formatos, e muitas vezes com padrões diferentes de unidade (e.g., padrões de data/horário: padrão americano – mês/dia/ano *versus* brasileiro – dia/mês/ano).

Como exemplo, pode ser citado o caso de sensores que produzem séries temporais (i.e., dados em função do tempo) para comportamento (e.g., pedômetros) e sensores para condições atmosféricas (i.e., temperatura, umidade, etc.). Nesse exemplo, muitas vezes almeja-se correlacionar eventos climáticos com possíveis respostas animais. Esse tipo de integração requer que os dados coletados por ambos os sensores estejam contidos em um mesmo conjunto de dados, devidamente indexados e sincronizados. A indexação se refere à identificação dos dados, ou seja, certo dado foi obtido pelo pedômetro, que estava no animal “A” no horário “X”. Nesse mesmo horário “X”, o sensor

2 coletava dados relativos ao clima em que o animal “A” estava submetido. Esse tipo de integração se torna mais complexa com o aumento da quantidade de dispositivos envolvidos e susceptível a erros. Como exemplos dessa vulnerabilidade, um cadastro incorreto de um animal em uma das plataformas pode causar não pareamento de dados; por outro lado, a assincronia dos relógios dos sensores pode gerar atribuição indevida (e.g., para um outro animal ou evento que não os que originaram o dado coletado). Assim, cabe ao analista conscientizar a equipe de campo sobre a responsabilidade da qualidade de coleta de dados e exigir que a mesma saiba manusear e utilizar corretamente todos os dispositivos. Falhas nesse nível podem inviabilizar todas as etapas *a posteriori*.

Após a seleção dos dados, procede-se ao pré-processamento. Essa etapa é marcada pelo ajuste de variáveis, transformações de unidades, identificação de dados faltantes, eliminação de dados ruidosos e identificação de *outliers*. Muitos equipamentos possuem algoritmos internos (i.e., não completamente con-

trolados pelo usuário) que se destinam a realizar esse tipo de pré-processamento. Embora esse procedimento automatizado reduza o trabalho do analista, e frequentemente torne os dados mais limpos, pode mascarar falhas dos sensores ou, muitas vezes, dificultar o casamento e integração da informação com outros dispositivos.

Embora o procedimento automatizado reduza o trabalho do analista, e frequentemente torne os dados mais limpos, pode mascarar falhas dos sensores ou, muitas vezes, dificultar o casamento e integração da informação com outros dispositivos.

Cabe aqui salientar que os dados podem ser de qualquer natureza, incluindo imagens, que podem ser pré-processadas para obtenção de dados como biometria animal e temperatura (câmeras termográficas). Esse tipo de procedimento foi, por exemplo, utilizado para determinação da angulação de dorso de vacas ao se locomoverem com o intuito de prever escores de claudicação (Viazzi *et al.*, 2013). Esse tipo de dado requer intenso e eficiente pré-processamento para obtenção dos dados.

As etapas seguintes do fluxograma do KDD não são muito comuns na pecuária de precisão. Segundo Fayyad *et al.* (1996), elas consistem na formatação e mineração de dados, cujo objetivo é buscar padrões no banco por meio de técnicas como: redução de dimensão por eliminação de variáveis (*e.g.*, componentes principais), transformação de variáveis (conversões lógicas, criação de classes) e por fim métodos clássicos como correlações, classificação (*i.e.*, análise de *cluster*), regressões de “Ridge” e árvores de decisão. Algumas típicas da área conhecida como aprendizagem de máquina (do inglês, *machine learning*) que, com base em uma parcela dos dados, envolve treinar o computador para que chegue a uma resposta baseada no cenário criado pela interseção de variáveis de entrada. Usam-se nesse processo de treinamento vários algoritmos, empregados para avaliação no restante do

banco de dados. Esse tipo de procedimento é conhecido como aprendizado supervisionado, visto que existe um padrão ouro para que se avalie a capacidade do modelo criado. Existem ainda métodos não supervisionados, que visam, a partir de características similares, classificar resultados. Como exemplo, pode-se citar as análises

de *cluster*, que têm como objetivo criar uma rede de similaridade entre possíveis classes.

As análises supracitadas dependem da integração de muitas variáveis, e até então poucos trabalhos avaliaram essas técnicas no âmbito da pecuária leiteira, usando dados não completamente coletados de forma automática, e com sucesso questionável (Shahinfar *et al.*, 2014a; Shahinfar *et al.*, 2014b). Segundo Rutten *et al.* (2013), a maioria dos dispositivos encontrados no mercado para detecção ou auxílio no manejo sanitário de rebanhos leiteiros falham no quesito integração de dispositivos. Esse cenário limita a aplicação de ferramentas como o aprendizado de máquina e análises multivariadas, sendo explicável do ponto de vista das empresas fabricantes, que tentam normalmente desenvolver solução para um problema específico, e poucas conseguem criar um pacote para a atividade como um todo. Nesse contexto, o diagrama proposto por esses autores é mais coerente com o que atualmente ocorre com os dados obtidos na pecuária de precisão leiteira (Fig. 2).

No diagrama (Fig. 2), o processo de geração de suporte para tomadas de decisão a partir de dados coletados automaticamente por um sensor é dividido em quatro estágios. No primeiro, o sensor captura dados a partir de um animal ou do ambiente. É possível que algum algoritmo atue junto ao *hardware* para

que o dado seja gerado. Exemplo disso são as balanças que trabalham com células de carga. Esses sensores trabalham gerando alterações de tensão (voltagem) e esta é linearmente convertida em unidades de massa por métodos de calibração. Esse tipo de conversão (volts para kg) caracteriza um algoritmo interno. A depender do recurso do equipamento, é possível que leituras consideradas fora de uma faixa específica sejam eliminadas ou gerem alertas, que podem representar erros de calibração (*i.e.*, o fator de conversão utilizado durante a calibração pode não estar correto ou não mais ser adequado, por exemplo, caso o sensor tenha fadigado). Caso os dados brutos não sejam passados para o banco exportado pelo dispositivo, o analista poderá não conseguir caracterizar esses tipos de *outlier*, e a informação poderá ficar de alguma forma viesada.

No próximo nível, os dados gerados são

interpretados por algoritmos previamente validados e um *status* é gerado, ou um valor é computado (*e.g.*, o animal está em estro). Esse tipo de algoritmo é também denominado modelo preditivo (um *status* é predito a partir dos dados). Para esse tipo de informação, é essencial o processo de validação, geralmente realizada pela metodologia de comparação dos *outputs* com um padrão ouro; mas, com o advento do sensor, o processo tornou-se mais efetivo, embora passível de questionamentos, pois numa perspectiva simplista trataria de um caso de falso positivo, isto é, o algoritmo em teste marcou como positivo ou presente um fenômeno que para o padrão ouro seria negativo. Assim, é preciso cautela e bom senso, pois pode caracterizar supervalorização das capacidades do sensor, o que não é bem aceito pela comunidade científica. A melhor saída é utilizar como padrão ouro métodos o mais sensível possível. Uma vez




Figura 2 – Diagrama do fluxo de dados e informações desde o processamento de dados coletados automaticamente à tomada de decisão pelo produtor e/ou equipe. Adaptado de Rutten *et al.* (2013).

que o algoritmo seja aceito, novas validações deverão ser realizadas tão frequentes quanto possível for, de forma a aumentar cada vez mais a sensibilidade e especificidade do algoritmo de detecção. Muitas vezes, para

se aumentar a acurácia dos dispositivos, a adição de informações obtidas *a priori* podem ser úteis, ainda que não advenham de sensores. Como exemplo pode-se citar o histórico de cios detectados. O intervalo relativamente regular do ciclo estral é uma informação bastante interessante, pois facilita a busca por comportamentos em intervalos regulares. O final da etapa 2 no fluxograma é caracterizado pela síntese da informação em si, objetivo similar ao processo de KDD. Os níveis 3 e 4 descritos por Rutten *et al.* (2013) são relativos à tomada de decisão.

O desenvolvimento de algoritmos preditivos requer habilidade estatística e entendimento dos conceitos básicos sobre modelagem de fenômenos. Nesse caso, o analista deve ter ampla capacidade de observação e abstração, além de ter foco na demanda proposta. É muito comum desviar-se da meta inicial durante o processo de modelagem, podendo, portanto, levar a conclusões não desejadas, além de perda de tempo e esforço (Tedeschi *et al.*, 2005).

Como passo inicial, o modelista deverá ser capaz de descrever o fenômeno por meio das variáveis coletadas, tendo a habilidade de reconhecer as distribuições das mesmas e características como instabilidade, variância, correlação entre elas, multicolinearidade, entre outros atributos que lhe permitirão aplicar às mesmas a técnica estatística mais adequada. Muitas vezes, a seleção de variáveis poderá ser essencial. Segundo o princípio reducionista conhecido como a “Navalha de Occam”, a

O desenvolvimento de algoritmos preditivos requer habilidade estatística e entendimento dos conceitos básicos sobre modelagem de fenômenos.

explicação de qualquer fenômeno deve assumir apenas as premissas estritamente necessárias à explicação do mesmo, de forma que as entidades não sejam adicionadas ao problema além da necessidade. Colocar essa

filosofia em prática implica reduzir ao máximo o nível de complexidade, ou dimensões geradas por variáveis desnecessárias, sem que se perca qualidade preditiva. Vários métodos estatísticos foram desenvolvidos para esse propósito, entre eles um dos mais populares na estatística aplicada a modelos lineares é o conhecido como método de regressão *stepwise*. Esse método de busca é caracterizado pelo ajuste de modelos de regressão em sequência onde cada uma das variáveis candidatas é adicionada a cada passo, e os modelos ajustados podem então ser comparados por várias técnicas como erros quadráticos médios, coeficientes parciais de correlação, estatística t ou F, critérios de Akaike ou Schwarz, entre outros (Kutner *et al.*, 2005). No âmbito da estatística multivariada, o uso da análise de componentes principais visa explicar a estrutura de variância-covariância das variáveis envolvidas por meio de poucas combinações lineares, resultando em redução de dados e possíveis inferências, como exemplo, quais variáveis são mais “impactantes” para o fenômeno (Wichern e Johnson, 2007).

Passada a etapa de ajuste, torna-se premente a avaliação dos modelos. Segundo Tedeschi (2006), o termo “validação” deve ser preterido nesses casos; pois, do ponto de vista filosófico, modelos são representações abstratas da realidade, de forma que nunca poderão mimetizar completamente a realidade em qualquer condição, dessa forma jamais será totalmente verdadeiro, correto e, portanto, válido. Uma interessante discussão a respeito

dessa temática foi apresentada por Sterman (2002) no texto “All models are wrong”, em que se tentou esclarecer como o mundo que nos cerca é complexo e que devemos ser humildes quanto à qualidade dos modelos. Assim, torna-se mais adequado o termo avaliação ou teste de modelos. Embora subestimada, a avaliação de modelos é etapa fundamental para o sucesso de dispositivos eletrônicos. Isso porque é nessa etapa em que se executaram testes para se avaliar a acurácia e precisão dos modelos que gerarão as respostas à demanda inicial. Modelos muito simples, essencialmente empíricos, podem acabar sendo muito precisos, mas pouco acurados, isto é, muitas vezes serão muito eficientes em prever resultados nas mesmas condições em que foram desenvolvidos, porém, poderão ter desempenhos insatisfatórios em condições adversas. Por outro lado, modelos muito complexos, excessivamente mecanicistas, embora geralmente sejam mais robustos e acurados, podem tornar a coleta de dados inexequível ou muito complexa.

Essa característica de poder preditivo deverá ser sempre estudada, pois essa avaliação trará como resultados não somente melhoras aos futuros modelos como também poderão sinalizar fragilidades dos sensores envolvidos no processo de coleta de dados, apontando lacunas que poderão dar margem ao desenvolvimento de novos dispositivos. No âmbito da estatística quantitativa, Tedeschi (2006) apresentou diversas técnicas e a interpretação das mesmas quando na avaliação de modelos. Do ponto de vista de dispositivos que visem detectar condições lógicas, ou binárias, por exemplo, o animal está doente ou não, em cio ou não, testes clássicos de especificidade e sensibilidade podem ser adequados. Em

Embora subestimada, a avaliação de modelos é etapa fundamental para o sucesso de dispositivos eletrônicos.

ambos os casos, pode-se aplicar a técnica de validação cruzada, cujo método baseia-se no uso de fragmentos de banco de dados para desenvolvimento dos modelos, com posterior uso

dos dados remanescentes como padrão ouro para avaliação dos modelos. Essa técnica é conhecida como *k-fold*, onde um conjunto de dados (k) é particionado em n subconjuntos dos dados ($k/n = k_i$) e o i -ésimo subconjunto é utilizado para desenvolvimento do modelo (ou aprendizado de máquina supervisionado), sendo sua capacidade preditiva sucessivamente avaliada frente aos resultados observados para os dados em $k - k_i$. Esse processo é repetido até que todos os subconjuntos tenham sido utilizados.

Caso um modelo seja aceito frente sua avaliação, pode-se dizer que se extraíram dos dados o conhecimento ou a informação necessária para suportar tomadas de decisão.

4. Tomada de decisão

Modelos de suporte a tomadas de decisão (DSS, do inglês *decision supporting systems*) têm como objetivo principal assistir ao usuário durante a solução de problemas cotidianos, muitas vezes subestimados quanto à sua complexidade. O uso desses modelos traz como benefício simplificar ou apontar soluções mais eficientes para se atingir um objetivo ou mais objetivos concomitantes. O cenário da pecuária leiteira é demasiadamente complexo, e uma miríade de forças são impostas simultaneamente ao sistema (*e.g.*, sustentabilidade social, econômica e ambiental), tornando humanamente impossível manejá-lo ao ponto de atender, de forma equilibrada, a todas essas demandas. Agrava-se nesse cenário o fato de que os níveis de um sistema são altamente integrados,

e interações diversas podem ocorrer, de forma que uma decisão tomada em um nível pode causar distúrbios nos demais. Esse tipo de cenário é altamente propício para aplicação de DSS; todavia, na pecuária leiteira, a adoção dessas ferramentas é muito baixa.

Segundo Newman *et al.* (2000), a baixa adoção desses sistemas deve-se à falta de coerência entre a real demanda dos pecuaristas e as capacidades do sistema e porque muitas vezes a capacidade e habilidade do produtor para operar e abastecer o sistema é insuficiente. Para o último caso, o uso de sensores automáticos, base da pecuária de precisão, tem potencial óbvio de sanar o problema para implementação de DSS em fazendas; entretanto, segundo pesquisa de Rutten *et al.* (2013), dispositivos capazes de prover suporte a esses sistemas são poucos ou inexistentes. Como abordado na Figura 2, esses dispositivos teriam de agir no âmbito dos níveis 3 e 4 do fluxograma proposto, os quais seriam integração da informação e tomada de decisão, respectivamente.

A falha na integração de dispositivos é recorrente entre os produtos disponíveis no mercado, e é uma das queixas de fazendeiros que limitam a adoção da pecuária de precisão (Bewley e Russel, 2010). Como citado anteriormente, as fabricantes têm como principal objetivo sanar problemas pontuais, sendo raros os pacotes de solução que seriam essenciais para a tomada de decisão. Ademais, ferramentas gerenciadoras da informação são escassas no mercado e, devido à quantidade de dados, normalmente são complexas e demandam treinamento e reciclagem constante de usuários. Além disso, sistemas como esses carecem de avaliações econômicas e, portanto, limitam tomadas de decisão eficientes quanto a esse quesito, o que causa insegurança em produto-

Do ponto de vista estatístico, o processo de suporte a tomadas de decisão é uma evolução da clássica abordagem da modelagem preditiva...

res que acabam optando por outras melhorias ou implementos para suas fazendas (Steenefeld e Hogeveen, 2015).

Do ponto de vista estatístico, o processo de suporte a tomadas de decisão

é uma evolução da clássica abordagem da modelagem preditiva, uma vez que o intuito é gerar opções a partir das previsões e informações geradas *a priori*, demonstrando os possíveis impactos advindos das decisões tomadas. Esse tipo de técnica é denominado modelagem prescritiva, uma vez que o sistema irá prescrever soluções e atitudes a serem tomadas e, em algumas situações, poderá ele mesmo tomar a decisão diretamente. Esse tipo de situação somente é possível para sistemas altamente sensíveis e específicos, pois para algumas decisões, erros podem ser drásticos. Na pecuária de precisão, sistemas prescritivos automatizados podem ser citados como aqueles em que o animal baseado em dados coletados por dispositivos são colocados em uma lista para apartação, e ao passarem por um corredor (e.g. brete) são automaticamente apartados por portões eletrônicos ou ao menos são identificados por painéis eletrônicos, sirenes, ou algo do tipo, para que o usuário saiba que aquele animal demanda atenção.

Na pecuária de precisão, exemplos desse nível de integração e fluxo bidirecional entre dispositivos e algoritmos em funcionamento ainda são escassos.

5. Exploração das informações

Em cenários de alta complexidade como o manejo de atividades leiteiras, por mais que dados sejam coletados automaticamente, modelos preditivos e prescritivos atuem eficien-

temente e soluções sejam propostas, faz-se essencial o desenvolvimento de ferramentas adequadas para visualização dos dados e interação entre homem e máquina. A evolução acelerada dos dispositivos pessoais portáteis, como *tablets* e *smartphones*, aproximou bastante as aplicações e ferramentas da informática com seus usuários, de forma que muitas pessoas se mantêm conectadas à internet ou redes pessoais 100% do dia. Esse fenômeno é altamente favorável à pecuária de precisão, contudo é essencial, principalmente em telas pequenas como a dos dispositivos móveis, que a informação seja apresentada da forma mais concisa possível, fomentando rápida interpretação e interação intuitiva. Criar interfaces entre máquina e humano é um desafio muito grande e muitos profissionais da área da ciência da informação têm se especializado nessa área que requer não só habilidade com os dados em si, mas também conhecimento de *design* entre outras disciplinas.

Surge nesse contexto a utilização de ferramentas visuais denominadas *dashboards*. Esse termo, que quer dizer painel de avião foi figurativamente adotado por cientistas da comunicação, pois resume o objetivo de seu emprego na visualização de dados, visto que o piloto de avião tem de ter disponíveis aos olhos, ainda que em frações de segundo, todas as informações necessárias para pilotar a aeronave, principalmente em momentos de emergência, para que possa tomar as decisões cabíveis.

Segundo Stephen Few, especialista da área da tecnologia da informação, a maior parte dos *dashboards* desenvolvidos para empresas falham em passar a informação, muitas vezes por *design* pobre, outras por focar em

...faz-se essencial o desenvolvimento de ferramentas adequadas para visualização dos dados e interação entre homem e máquina.

informação não necessária para o monitoramento.

Na pecuária de precisão, *dashboards* têm de ser desenvolvidos para trazer ao usuário as notificações, alertas e *status* de forma clara e direta. Devem, além

disso, ser personalizáveis de acordo com o perfil do usuário, já que diferentes tomadas de decisão deverão ser propostas, assim como as atitudes a serem tomadas. Esse tipo de ferramenta ainda é escasso no mercado, e a maior parte dos *software* trabalham com relatórios tradicionais que requerem muitas vezes interpretação excessiva dos usuários.

6. Considerações finais

A pecuária de precisão envolve mensurações, predições e análise de dados de variáveis dos animais e do ambiente, permitindo um extraordinário fluxo de informações coletadas automaticamente, gerando uma infinidade de possibilidades de controle e intervenções que são impossíveis dentro dos sistemas tradicionais de produção.

Apesar de estar em fase inicial de desenvolvimento e adoção, o avanço tecnológico em diversas áreas tem permitido que novos sensores e equipamentos cheguem à pecuária com custos cada vez mais acessíveis. Entretanto, para que essas novas tecnologias possam auxiliar a rápida tomada de decisões pelos produtores, os dados registrados precisam ser devidamente interpretados por *software* e modelos matemáticos, sendo imprescindível a interdisciplinaridade no desenvolvimento de novas ferramentas úteis ao setor produtivo.

A aplicação dessas novas tecnologias pode ge-

A aplicação dessas novas tecnologias pode gerar grandes modificações dentro da cadeia produtiva...

rar grandes modificações dentro da cadeia produtiva com a criação de novos setores de serviço, novas demandas pelos consumidores, rastreabilidade dos produtos, melhoria na eficiência do uso de recursos, aumento no bem-estar animal e das pessoas que trabalham nas fazendas, redução do impacto ambiental e maior lucro e sustentabilidade ao sistema. A pecuária de precisão mudará a maneira como rebanhos leiteiros serão gerenciados.

7. Referências bibliográficas

1. BALDWIN, R. L. *Modeling ruminant digestion and metabolism*. Great Britain: Chapman & Hall, 1995. p.583
2. BEWLEY, J. M.; RUSSEL, R. A. *Reasons for Slow Adoption Rates of Precision Dairy Farming Technologies: Evidence from a Producer Survey*. In: The first North American Conference on Precision Dairy Management. Minnesota. 2010. p.
3. FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. *AI Magazine*, v. 17, n. 3, p. 37-54, 1996.
4. KUTNER, M. H.; NACHTSHEIM, C. J.; NETER, J.; LI, W. *Applied linear statistical models*. New York: McGraw-Hill/Irwin, 2005.
5. NEWMAN, S.; LYNCH, T.; PLUMMER, A. A. Success and failure of decision support systems: Learning as we go. *Journal of Animal Science*, v. 77, n. E-Suppl, p. 1-12, 2000.
6. RUTTEN, C. J.; VELTHUIS, A. G.; STEENEVELD, W.; HOGEVEEN, H. Invited review: sensors to support health management on dairy farms. *J Dairy Sci*, v. 96, n. 4, p. 1928-52, 2013.
7. SHAHINFAR, S.; KALANTARI, A. S.; CABRERA, V.; WEIGEL, K. Short communication: Prediction of retention pay-off using a machine learning algorithm. *J Dairy Sci*, v. 97, n. 5, p. 2949-52, 2014a.
8. SHAHINFAR, S.; PAGE, D.; GUENTHER, J. et al. Prediction of insemination outcomes in Holstein dairy cattle using alternative machine learning algorithms. *J Dairy Sci*, v. 97, n. 2, p. 731-42, 2014b.
9. STEENEVELD, W.; HOGEVEEN, H. Characterization of Dutch dairy farms using sensor systems for cow management. *J Dairy Sci*, v. 98, n. 1, p. 709-17, 2015.
10. STERMAN, J. D. All models are wrong: reflections on becoming a systems scientist. *System Dynamics Review*, v. 18, n. 4, p. 501-531, 2002.
11. TEDESCHI, L. O. Assessment of the adequacy of mathematical models. *Agricultural Systems*, v. 89, n. 2-3, p. 225-247, 2006.
12. TEDESCHI, L. O.; FOX, D. G.; SAINZ, R. D. et al. Mathematical models in ruminant nutrition. *Scientia Agricola*, v. 62, n. 1, p. 76-91, 2005.
13. VIAZZI, S.; BAHR, C.; SCHLAGETER-TELLO, A. et al. Analysis of individual classification of lameness using automatic measurement of back posture in dairy cattle. *J Dairy Sci*, v. 96, n. 1, p. 257-66, 2013.
14. WICHERN, D. W.; JOHNSON, R. A. *Applied multivariate statistical analysis*. 6th. Pearson, 2007.