



Inteligência artificial aplicada à Zootecnia

Ernane José Xavier Costa¹

¹Universidade de São Paulo - Faculdade de Zootecnia e Engenharia de Alimentos. +55 19 35654177

RESUMO - Os sistemas biológicos são surpreendentemente flexíveis pra processar informação proveniente do mundo real. Alguns organismos biológicos possuem uma unidade central de processamento denominada de cérebro. O cérebro humano consiste de 10^{11} neurônios e realiza processamento inteligente de forma exata e subjetiva. A Inteligência Artificial (IA) tenta trazer para o mundo da computação digital a heurística dos sistemas biológicos de várias maneiras, mas, ainda resta muito para que isso seja concretizado. No entanto, algumas técnicas como Redes neurais artificiais e lógica fuzzy tem mostrado efetivas para resolver problemas complexos usando a heurística dos sistemas biológicos. Recentemente o numero de aplicação dos métodos da IA em sistemas zootécnicos tem aumentado significativamente. O objetivo deste artigo é explicar os princípios básicos da resolução de problemas usando heurística e demonstrar como a IA pode ser aplicada para construir um sistema especialista para resolver problemas na área de zootecnia.

Palavras-chave: algoritmos genéticos, redes neurais artificiais, sistemas especialista

Artificial intelligence in Animal Science

ABSTRACT- Biological systems are surprising flexible in processing information in the real world. Some biological organisms have a central unit processing named brain. The human's brain, consisting of 10^{11} neurons, realizes intelligent information processing based on exact and commonsense reasoning. Artificial intelligence (AI) has been trying to implement biological intelligence in computers in various ways, but is still far from real one. Therefore, there are approaches like Symbolic AI, Artificial Neural Network and Fuzzy system that partially successful in implementing heuristic from biological intelligence. Many recent applications of these approaches show an increased interest in animal science research. The main goal of this article is to explain the principles of heuristic problem-solving approach and to demonstrate how they can be applied to building knowledge-based systems for animal science problem solving.

Key Words: artificial neural network, genetic algorithm, knowledge-based system

Introdução

Introdução aos paradigmas da IA

A inteligência artificial (IA) compreende os métodos, ferramentas e sistemas para solucionar problemas que normalmente requer o uso da inteligência humana. Não somente os humanos podem resolver problemas complexos, mas todos os seres orgânicos também apresentam métodos avançados de solução de problemas complexos e uma capacidade de reação adaptativa. Sendo assim pode-se expandir o termo "inteligência artificial" à tentativa de sistematizar a resolução de problemas a partir da observação dos sistemas complexos existentes na natureza viva. Quando tais sistemas vivos identificam um problema eles reagem de forma adaptativa realizando tarefas complexas como:

- Reconhecimento de padrões em imagens e sons
- Processamento da linguagem

- Planejamento e predição de ações.

A partir do conhecimento destes sistemas complexos, a IA tem como objetivo principal desenvolver métodos e modelos que simulam em um sistema computacional a forma como os organismos vivos resolvem problemas. Para atingir estes objetivos a IA adota dois paradigmas: A IA simbólica baseada na teoria dos sistemas físicos simbólicos (Newel & Simon 1972) e a Neurocomputação (ou paradigma sub-simbólico) que está baseada na concepção conexionista dos neurônios para processar a informação (Smolenski, 1990).

O sistema simbólico consiste de um conjunto de símbolos que formam estruturas e um conjunto de regras e processos. Quando o conjunto de regras e processos é aplicado no conjunto de símbolos o sistema produz novas estruturas. Os símbolos têm significados semânticos e podem representar conceitos ou objetos. Para lidar com

estes conceitos usa-se a lógica proposicional e a lógica de predicados o que permite a solução de problema usando um sistema baseado em regras. Assim um sistema simbólico é capaz de resolver problemas que envolvem dados e as regras sobre estes dados.

O paradigma conexionista tem como premissa a suposição de que o comportamento inteligente esta relacionado com a dinâmica das conexões entre pequenos nós denominados neurônios onde tal dinâmica é capaz de representar o conhecimento. Diferentemente do paradigma simbólico, no modelo conexionista o estado dos neurônios representam um conceito ou um objeto e a dinâmica que leva à representação do conceito ou objeto é que estabelece as regras sobre tais objetos e conceitos. Na pratica, os dois paradigmas podem se juntar para formar um terceiro paradigma, uma mistura do sistema simbólico com um sistema conexionista.

Resolução de problemas usando Heurística

Heurística é uma palavra de origem grega que significa descoberta. O ato humano de resolver um problema implica uma ação heurística na sistemática da resolução do problema. Esta sistemática baseia-se na experiência, idéias racionais, e regras. De fato, naturalmente a heurística esta baseada mais no senso comum que em um formalismo matemático, o que a princípio, não implica que a heurística garantirá a melhor solução para um dado problema, mas com certeza a solução será ótima em termos de custo e tempo. O exemplo disso é a forma como os humanos resolvem problemas que não tem uma fórmula ou algoritmos que permita encontrar a solução exata e direta como, por exemplo, diagnosticar um

defeito em um automóvel ou criar um plano para aumentar a produção de leite de uma dada fazenda. O desafio da IA é estabelecer métodos que possam sistematizar a maneira heurística de resolução de problemas e transcrevê-las para um formalismo matemático e algorítmico possibilitando assim seu uso em máquinas automáticas como o computador.

Na ciência zootécnica, como em outras, quando um problema é definido, assume-se que existe um conjunto de n variáveis independentes de entrada ou atributos do problema (x_1, x_2, \dots, x_n) , e um conjunto de m variáveis que representam, a partir de regras ou observações, as possíveis soluções do problema (y_1, y_2, \dots, y_m) . Cada possível combinação dos valores das variáveis de entrada podem ser representada por um vetor $\vec{d} = (a_1, a_2, \dots, a_n)$, em que \vec{d} é um elemento do espaço de domínio \mathbf{D} ou espaço dos problemas. Por outro lado, cada possível solução y pode ser representada como um vetor $\vec{s} = (s_1, s_2, \dots, s_m)$, em que \vec{s} é um elemento do espaço de soluções \mathbf{S} . No caso ideal existe uma formula ou procedimento que permite estabelecer diretamente para cada problema em \mathbf{D} uma solução em \mathbf{S} , Mas na realidade da zootecnia isto nem sempre acontece e é nestes casos que a heurística é usada. A heurística é um mecanismo segundo o qual problemas no espaço \mathbf{D} podem ser mapeados no espaço das soluções. Este procedimento está ilustrado na Figura 1.

A inteligência artificial estabelece os mecanismos que permitem sistematizar os métodos heurísticos. Logo, o termo inteligência aqui não é estritamente a inteligência humana, mesmo porque a definição de inteligência é complexa. Mas o termo pode ser considerado como o uso

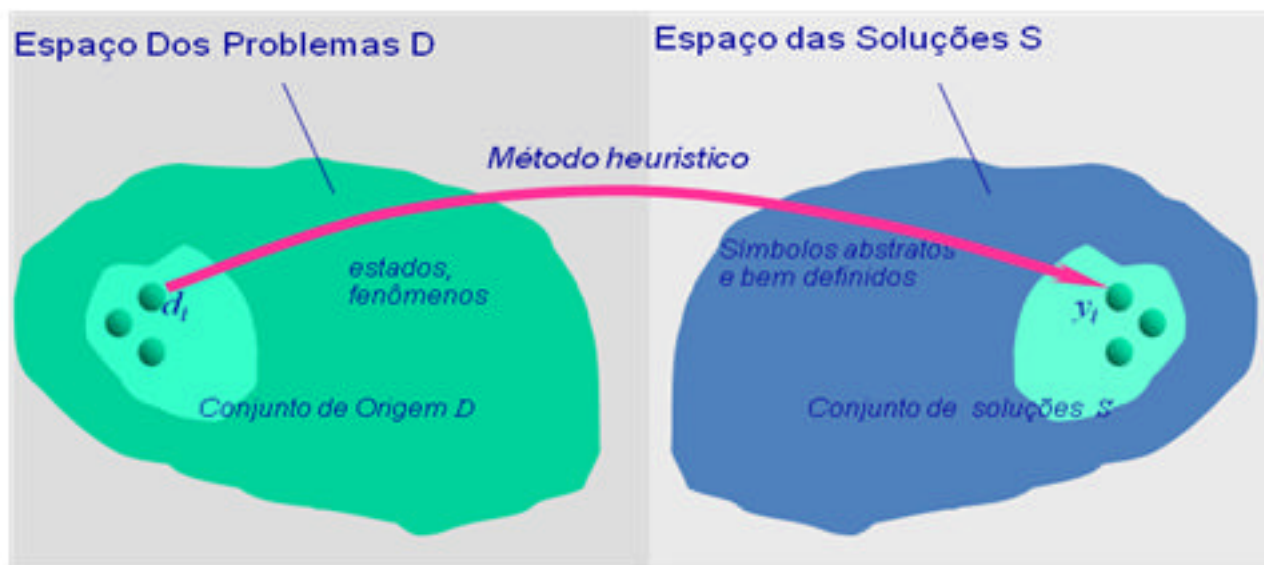


Figura 1 – Heurística como um meio de obter soluções no espaço S a partir das variáveis existentes no espaço de domínio D.

da heurística na resolução de problemas. Os dois exemplos mais elucidativos da heurística são: Algoritmos genéticos e Redes neurais Artificiais.

Algoritmos genéticos

Os algoritmos genéticos (AG) são capazes de resolver problemas complexos de problemas combinatórios e organizacionais. Os algoritmos genéticos se inspiram nas leis naturais da genética evolutiva e foi introduzida e sistematizada no meio acadêmico por Jonh Holland (1975). Pode-se de classificar os algoritmos genéticos dentro da IA como um paradigma simbólico.

Pela observação da diversidade das variedades de seres vivos, surge a questão: Como a natureza resolve o problema de otimização observado na evolução das espécies e sua conseqüente adaptação ao meio? Uma das respostas foi dada por Darwin na teoria da evolução. Partindo-se desta inspiração um algoritmo genético é um algoritmo que se baseia nos seguintes processos e objetos:

Gene – um objeto básico que controla a propriedade de um indivíduo

Cromossomo – um vetor de genes, representa um indivíduo ou uma solução possível de um dado problema no espaço de soluções S.

População – uma conjunto de indivíduos

Operação de Crossover – ação que a partir de um subconjunto de genes de indivíduos produz novos indivíduos.

Mutação – uma mudança aleatória nos genes de um cromossomo

Figura de mérito – um critério de avaliação de cada indivíduo

Seleção – um procedimento de escolha de uma parte da população de indivíduos que irão permanecer no processo de busca da solução ótima do problema. A seleção é baseada na figura de mérito pré-estabelecida.

Um algoritmo genético simples consiste das seguintes etapas:

1- Inicializar as populações de possíveis soluções do problema

2- Enquanto a melhor solução baseada em algum critério não for encontrada faça:

a. Use a operação de crossover entre um indivíduo “pai” e um indivíduo “mãe” da população e gere novos indivíduos

b. Selecione os melhores “filhos” gerados usando uma função de mérito

c. Aplique mutações de forma aleatória e rara.

Para exemplificar o uso de um AG na solução de um

problema, considere o seguinte exemplo: Alguém pensa um número compostos de zeros e uns, por exemplo: 101011

O problema consiste em descobrir a partir de um chute inicial qual foi o numero pensado. Os zeros e 1's representam genes e o numero inteiro representa um individuo. A figura de mérito é dada pelo numero de genes na posição correta. Usando o algoritmo genético a solução será encontrada. Por exemplo:

Considere que o chute inicial é :

a) 010101 ACERTOS 1

b) 111100 ACERTOS 2

c) 011011 ACERTOS 4

d) 101100 ACERTOS 3

Usando a figura de mérito os indivíduos c) e d) são os mais adaptados pois tiveram o maior número de acertos. Tomando c) como mãe e d) como pai e realizando um compartilhamento simples de genes entre eles tem-se:

c) **01**:1011 e) **01**:1100 ACERTOS 1

d) **10**:1100 f) **10**:1011 ACERTOS 6 - SOLUÇÃO

ENCONTRADA

Nota-se neste exemplo que bastou uma iteração no algoritmo para encontrar a solução ótima. Este algoritmo pode ser adaptado para trabalhar com n variáveis onde cada variável é um gene e cada conjunto de variáveis uma solução possível do problema. Em um problema zootécnico hipotético de encontrar a melhor combinação de ingrediente de uma ração que ao mesmo tempo otimiza o custo da ração e o ganho de peso do animal, o algoritmo genético poderia ser usado onde as variáveis que representam ingredientes seriam genes e os indivíduos seria conjunto destas variáveis a figura de mérito poderia ser o ganho de peso do animal e o custo da formulação ponderados em uma equação ou em observações experimentais. O AG é um exemplo simples de um método heurístico sistematizado dentro dos conceitos da IA.

Redes neurais artificiais

Os cérebros, sob uma visão simplista, são formados por unidades básicas denominadas de neurônios. Os neurônios estão conectados em uma rede complexa e dinâmica. Nos seres vivos esta estrutura é capaz de resolver problemas complexos. Desta observação surge dentro da IA o modelo conexionista que é um método heurístico inspirado no funcionamento das redes neurais. As redes neurais artificiais são, portanto, um algoritmo computacional de uma rede de neurônios artificiais. Um neurônio artificial é por outro lado um modelo matemático inspirado em um neurônio real (HAYKIN, 1991). A palavra inspirado é usado aqui para deixar claro que o modelo

matemático é muito simples quando comparado com a complexidade de um neurônio real.

O modelo matemático de um neurônio artificial é mostrado na Figura 2.

Neste Modelo:

- Sinais são apresentados à entrada.
- Cada sinal é multiplicado por um número (peso).
- É feita a soma ponderada que produz um nível de atividade.
- Se este nível de atividade exceder um limite, a unidade produz uma determinada resposta de saída.

McCulloch and Pitts (1943) criaram um modelo matemático de um neurônio e denominaram-no de perceptron mostrando que uma associação de perceptrons (ou rede de perceptrons) é capaz de implementar qualquer função lógica finita.

A associação de neurônios artificiais altamente




Figura 2 - Modelo matemático de um neurônio, proposto por McCulloch and Pitts e denominado Perceptron.

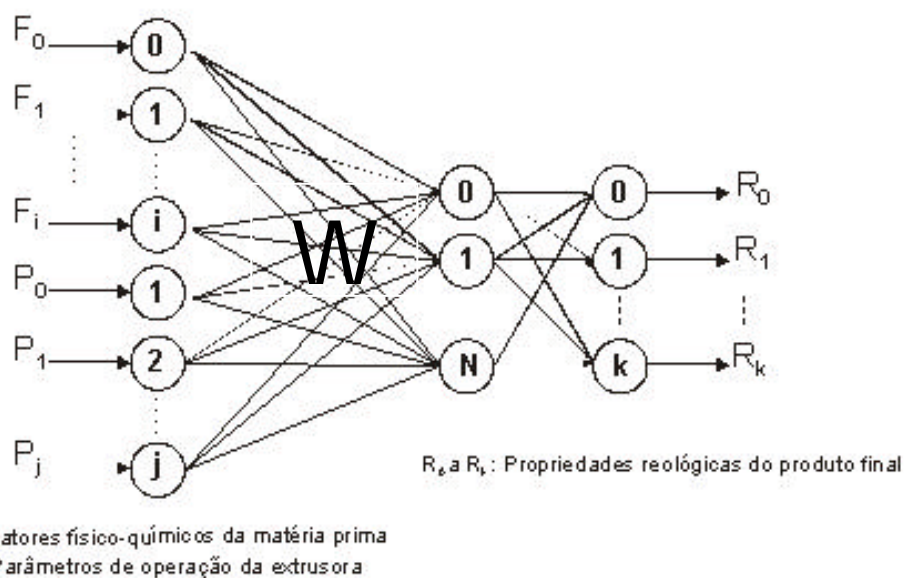


Figura 3 - Estrutura de uma rede neural capaz de relacionar os parâmetros de entrada representadas por F e P com as características da saída representadas por R através da matriz sináptica W.

As RNAs possuem a capacidade de aprendizado, e podem ser supervisionadas ou não. É demonstrado que a rede neural supervisionada pode “aprender” ou encontrar qualquer função contínua. É esta capacidade de lidar com funções altamente complexas que tornam as RNAs úteis no estudo de problemas tecnológicos, tais como a previsão de determinadas parâmetros zootécnicos. Existem muitas pesquisas que mostram a viabilidade do uso de RNAs para modelar, prever e classificar dados zootécnicos.

3- Reconhecimento de padrões em dados zootécnicos usando o modelo conexionista:

Um dos principais atributos do modelo conexionista é a capacidade de generalizar a partir de exemplos. O modelo é baseado na codificação da informação em matrizes sinápticas que representam as conexões entre os neurônios da rede. O uso das RNAs no reconhecimento de padrão pode ser esquematizado conforme ilustra a Figura 4.

Os dados obtidos de um sistema zootécnico são armazenados em uma base de dados. A base de dados pode estar relacionada com regras e rótulos que caracterizam os dados transformando a base de dados em uma base de conhecimento. Os dados da base de conhecimento possuem certas características que podem ser únicas e, portanto servir de identificação. Este processo é denominado extração de características. Normalmente os dados não são diretamente introduzidos no sistema de classificação, antes eles podem sofrer transformações que resultam em características que reduzem ou aumentam a dimensionalidade dos dados. Após a extração das características, estas podem ser usadas no treinamento e no teste do classificador. Os dados usados para treinar o classificador não podem ser usados no teste. Para testar a

rede um conjunto novo de dados deve ser apresentado ao classificador. Os acertos e os erros do classificador permitem que uma abordagem estatística seja usada para avaliar seu desempenho.

O sistema descrito na figura 4 pode ser realizado por uma rede neural que pode “aprender” o padrão existente em certo conjunto de dados. No contexto conexionista “aprender” é um processo pelo qual os parâmetros livres de uma RNA, são dinamicamente alterados através da interferência do ambiente externo ou dados provenientes de medidas do mundo real.

A forma como os parâmetros são modificados definem a forma como a rede representará o conhecimento. Em artigos recentes na área de zootecnia a aprendizagem por correção de erro é a forma mais usada. Para ilustrar esta aprendizagem, considere um vetor de funções que representam algumas características de um sistema zootécnico qualquer e dado por:

$x(n) = [x_1(n), x_2(n), \dots, x_k(n), \dots]$, em que cada uma das coordenadas i entra em um neurônio k através de um peso sináptico dado por W_{ik} . Pode-se representar esquematicamente este modelo com a Figura 2. Pode-se afirmar que a Figura 2 constitui um nó computacional simples. Por simplicidade o aprendizado por correção de erro pode ser compreendido usando este simples nó computacional. Neste nó podemos visualizar uma saída gerada através da função de ativação h do neurônio aplicada na entrada $x(n)$, no entanto, esta saída pode gerar um erro caso não seja igual a solução $y(n)$ desejada. Este processo pode ser visualizado na Figura 5.

Existem na literatura científica vários exemplos de aplicação do paradigma conexionista usando o método de

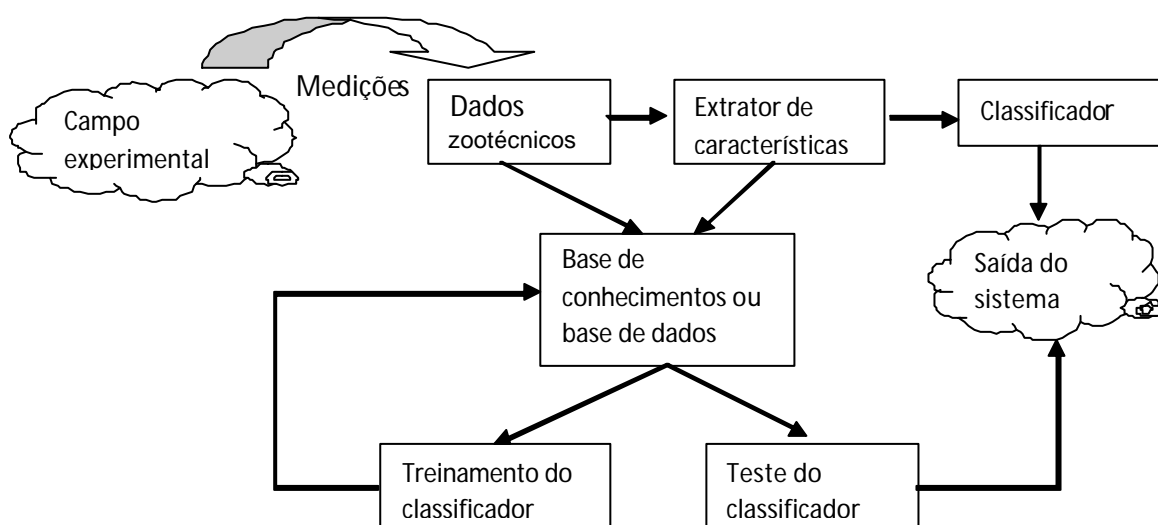


Figura 4 - Diagrama funcional de sistema de reconhecimento de padrões.

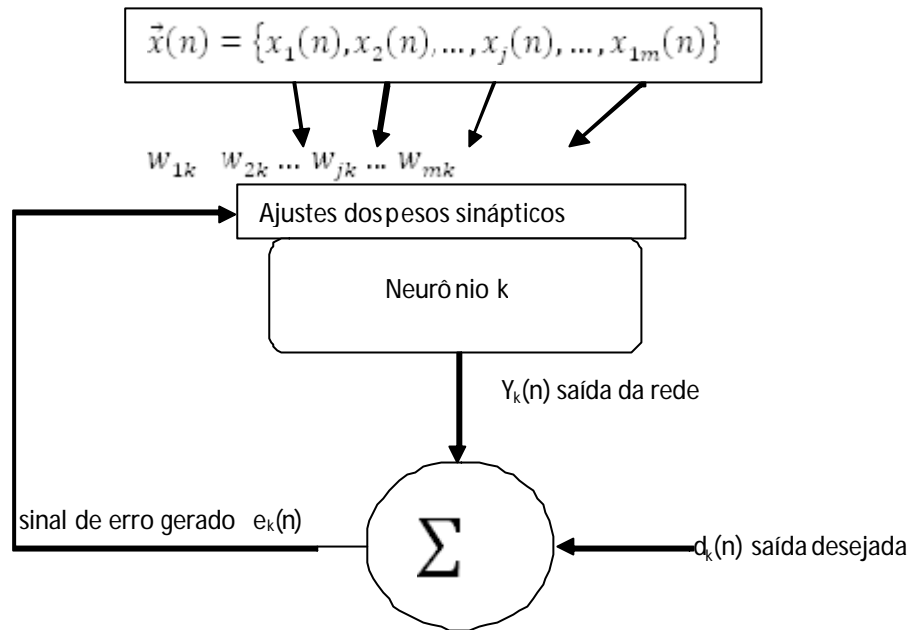


Figura 5 - Diagrama esquemático do processo de aprendizagem por correção do erro.

correção de erro de aprendizagem para resolver problemas zootécnicos. Brenneke 2007, usou um rede neural para a predição de proteína bruta e suas frações usando uma base de dados que incluiu as variáveis como tamanho, cor das folhas, média da altura pré-pastejo latitude e longitude, perfilho novos, perfilho remanescentes e etc. Neste trabalho a partir de dados externos da planta a autora mostrou que a RNA conseguiu estabelecer uma relação entre estas variáveis externas e seu conteúdo de proteína bruta. As redes neurais também foram usadas com sucesso em estudos aplicados em avicultura como previsão de qualidade de carcaça e avaliação da dieta de frangos de corte para estabelecer padrões que possam relacionar a qualidade do produto com o ambiente de criação e o alimento recebido (Hamadi et al., 2007; Chen et al., 1998). Em estudos visando à previsão de mastite bovina as redes neurais artificiais foram usadas como um sistema de diagnóstico precoce baseado em dados de monitoramento diário coletados durante as ordenhas e armazenados em uma base de conhecimento para assim detectar com antecedência o surgimento da mastite bovina nos animais em estudo (Cavero et al., 2008; Heald et al., 2000).

Na suinocultura também existem trabalhos recentes destacando-se o trabalho de Kevin et al. (2004) que modelaram o odor em função de diversas variáveis do ambiente e assim conseguir atuar na granja no momento certo para controlar o odor exalado. Na bovino cultura as RNA tem sido usadas em diversos problemas e estudos como modelagem do rumem (Craninx et al., 2008) e em

estimativa de ganho de peso (Arias et al., 2004). Em todas estas aplicações a IA usou o modelo conexionista através de uma rede de neurônios artificiais supervisionada usando aprendizagem por correção de erro.

Considerações Finais

A Inteligência artificial, principalmente no que diz respeito ao modelo conexionista, pode ser considerada sistemas de processamento de informações e, como tal, são dispositivos que aceitam entradas e produzem em geral, saídas que são mais adequadas para esta ou aquela aplicação de interesse do usuário. No atual estágio de desenvolvimento das RNAs, existe um grande número de aplicações, mas em todas estas aplicações existe um fator preponderante e que em momento algum pode ficar de fora do sistema inteligente. Este fator é o especialista. E no caso da zootécnica o especialista é o zootecnista, o único capaz de fazer com que o poder da IA seja usado para melhorar a nossa produção de alimentos de origem animal e, é ele que deve buscar a interdisciplinaridade atuando juntamente em áreas como a instrumentação eletrônica e a computação para cada vez mais melhorar a forma como resolvemos problemas complexos na área de zootecnia.

Literatura Citada

AHMADI, H.; MOTTAGHITALAB, M.; NARIMAN-ZADEH, N. Group method of data handling-type neural network prediction of broiler performance based on dietary metabolizable energy,

- methionine, and lysine. **Journal of Applied Poultry Research**, v.16, p.494-501, 2007.
- ARIAS, N.A.; MOLINA, M.L.; GUALDRON, O. Estimate of the weight in bovine livestock using digital image processing and neural network. **Proc. SPIE**, v.562, p.224, 2004.
- BRENNECKE, K. **Fracionamento de carboidratos e proteínas e a predição da proteína bruta e suas frações e das fibras em detergentes neutro e ácido de Brachiaria brizantha cv. Mandaru por um arede neural artificial**. 2007. 138f. Tese (Mestrado em Zootecnia) – Faculdade de Zootecnia e Engenharia de Alimentos/Universidade de São Paulo, Pirassununga, 2007.
- CAVERO, D.; TOLLE, K.H.; HENZE, C. et al. Mastitis detection in dairy cows by application of neural networks. **Journal of Food Process Engineering**, v.114, p.280-286, 2008.
- CHEN, Y.R.; NGUYEN, M.; PARK, B. Neural network with principal component analysis for poultry carcass classification. **Journal of Food Process Engineering**, v.21, p.351-367, 1998.
- CRANINX, M.; FIEVEZ, V.; VLAEMINCK, B. et al. Artificial neural network models of the rumen fermentation pattern in dairy cattle. **Computers and Electronics in Agriculture**, v.60, n.2, p.226-238, 2008.
- HAYKIN, S. **Redes neurais artificiais princípios e práticas**. 2.ed. Bookman, 2002. 900p.
- HEALD, C.W.; KIM, T.; SISCHO, W.M. et al. A computerized mastitis decision aid using farm – based records: an artificial neural network approach. **Journal of Dairy Science**, v.83, p.711-720, 2000.
- HOLAND, J. **Adaptation in natural and artificial systems**. 1.ed. Mit Press, 1992. 345p.
- JANES, K.R.; YANG, S.X.; HACKER, R.R. Pork farm odour modelling using multiple- component multiple-factor analysis and neural networks. **Applied Soft Computing**, v.6, p.53-61, 2005.
- NEWELL, A.; SIMON, H.A. **Human problem solving**. 1.ed. Prentice Hall, 1972. 321p.
- SMOLENSKI, P. Tensor product variable binding and the representation os symbolic structures in connectionist systems. **Artificial Intelligence**, v.46, p.159-215. 1990.