

Utilização de Redes Neurais Artificiais em colheitas de cana-de-açúcar para predição de PCC, TCH e fibra

Diogo F. Pacheco, Filipe S. Regueira, Fernando Buarque de Lima Neto
{diogofpacheco@yahoo.com.br, filiperegueira@yahoo.com.br, fbln@upe.com.br }

Resumo

Aparentemente de fácil execução, a colheita da cana-de-açúcar, inclui um processo decisório muito complexo. Ele influencia diretamente na produtividade e, conseqüente, lucratividade de toda a safra agrícola.

Se tratados independentemente, o grande volume de informações disponibilizadas durante a operação de usinas sucro-alcooleira, agregam pouco valor à decisão de gestores sobre quais lotes devem ser colhidos. Utilizando-se técnicas de redes neurais artificiais para a modelagem do problema da colheita da cana-de-açúcar, pode-se disponibilizar, antecipadamente, informações gerenciais com mais precisão e pertinência. São exemplos de informações que podem ser antecipadas: PCC, TCH e fibra.

Os resultados experimentais obtidos neste trabalho possibilitam a construção de uma ferramenta que implemente e estenda o modelo ora utilizado para gerar curvas de maturação das variedades de cana-de-açúcar em vários cenários de decisão. Isto permitiria ao agente de decisão conhecer, com relativa precisão, o momento exato para a colheita de qualquer variedade cultivada em sua unidade.

1. Introdução

A cultura da cana-de-açúcar gera por ano milhões de dólares em todo o mundo [ALCOOLBrás04]. No nordeste brasileiro, se destaca como uma das principais atividades econômicas, notadamente como insumo fundamental para a produção de açúcar, álcool e combustível.

Altos rendimentos na indústria sucro-alcooleira dependem diretamente da qualidade do vegetal colhido. Essa qualidade, por sua vez, depende de uma série de atividades agrícolas: plantio, tratos culturais e colheita. Aparentemente de fácil execução, a última destas, a colheita da cana-de-açúcar, inclui um processo decisório muito complexo. Este, refletindo diretamente na produtividade e conseqüente, lucratividade de toda a safra agrícola. Contribuem para essa complexidade inúmeros fatores ligados à maturação da cana-de-açúcar [Alexander73]. Conseqüentemente, durante uma colheita, todo gerente agrícola, se depara com a difícil pergunta: quais lotes devem ser selecionados para colheita?

Apesar da informatização que é praticamente regra em todas as grandes usinas que produzem açúcar e álcool, os atuais gestores dispõem de poucas ferramentas que os auxiliem mais efetivamente na decisão de colheita da matéria prima [Buarque98]. Na prática, os gerentes apenas dispõem de uma miríade de linhas de informações em relatórios/consultas em tela sobre os lotes plantados. Não raro as informações disponíveis são: variedade da cana, topografia, época do plantio, tipo do solo, PCC de safras anteriores etc. Assoma-se a essas amostras: resultados de análises laboratoriais de pré-colheita e muitas outras informações industriais.

Da maneira como atualmente são apresentadas as informações para decisão de colheita, elas agregam pouco valor ao processo gerencial que é praticamente empírico. Isto, pois, não são consideradas todas as possíveis interconexões existentes nos dados atuais. Em atendimento a essa necessidade, exemplos da literatura especializada demonstram a eficiência de redes neurais artificiais, i.e. programas de computador que utilizam inteligência artificial, como ferramentas de suporte a decisão para a colheita de cana-de-açúcar [Buarque98].

Utilizando-se técnicas de redes neurais para a modelagem de problemas como o da colheita da cana-de-açúcar, pode-se disponibilizar antecipadamente informações gerenciais, com mais precisão e pertinência. Isto além de se incluir a possibilidade do gestor poder agregar a sua

experiência à forma como uma ferramenta que use tecnologia neural (i.e. computação inteligente) faz previsões. Por exemplo, a respeito da qualidade dos lotes a serem colhidos: predição dos valores de PCC, fibra e TCH.

Este trabalho apresenta novas modelagens para o problema da colheita da cana-de-açúcar e inclui simulações usando redes neurais artificiais, onde se conseguiu atingir ainda melhores resultados principalmente na previsão do TCH, em relação aos trabalhos anteriores em [Buarque98]. Naquele trabalho anterior, sequer se alcançou 50% de acerto aceitável, enquanto no presente trabalho, obtivemos 78%. Os valores de PCC e fibra permanecem compatíveis, e continuam acima dos 95% e 90%, respectivamente.

2. Metodologia

Redes neurais artificiais foram concebidas, i.e. inspiradas, no funcionamento sistema nervoso. Sem dúvidas, nosso sistema mais complexo. Ou seja, tenta-se simular no computador o modo como o cérebro processa informações. Isto para incluir características necessárias para a resolução de problemas complexos e com alto volume de informações. Essas novas qualidades acrescidas à computação tradicional transformam o computador numa plataforma que se adapta aos problemas, têm alto grau de paralelismo, generalização e associatividade. E a mais importante de todas, aprender usando acertos e erros passados.

2.1 Redes neurais artificiais (RNA)

Redes neurais artificiais oferecem a possibilidade de resolver problemas complexos e fazer previsões [Haykin94]. Em especial, usando a topologia *Multi-Layer Perceptron* (MLP) com comprovado poder computacional [Minsky69]; como demonstrado em vários trabalhos das mais diversas áreas de conhecimento: [Fu-Liu04], na medicina, [Sinha98], no reconhecimento de imagens, [Park04] na agricultura e em particular, no problema da colheita da cana-de-açúcar [Buarque98]. Todo conhecimento adquirido pelas RNAs é passado através de exemplos, que ajustam os pesos (sinapses) dos neurônios.

Uma definição de RNA:

“Uma rede neural é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso.” [Haykin94]

Diferentemente de outras técnicas de computação convencional, RNA necessitam de que o conhecimento lhes seja “ensinado” antes que este possa ser utilizado. Para isso, diversos parâmetros computacionais devem ser ajustados (n° de neurônios, n° de camadas escondidas, entre outros), de modo que, ao final do treinamento, a rede neural seja capaz de fazer previsões diversas. Por exemplo: predições de PCC, TCH e fibra, sobre determinado lote. Tudo isto, para qualquer instante da curva de maturação da variedade de cana-de-açúcar em questão.

Escolha do paradigma de aprendizado:

“Paradigma supervisionado é indicado quando se possui um conjunto de dados de treinamento composto dos valores das Entradas e Saídas.” [Buarque98]

2.2 Modelagem do Problema

O foco principal deste trabalho foi estender as pesquisas anteriores na área [Buarque98], intensificando as simulações, a fim de obter melhores resultados na predição da tríade PCC, TCH e fibra. A modelagem utilizada para o problema foi a mesma usada anteriormente, consistindo de pré-processamento (i.e. normalizados e randomizados) dos dados brutos obtidos de uma unidade agro-industrial do interior do Estado de São Paulo. Em seguida os dados resultantes considerados/descartados nas diversas simulações procedidas foram:

Entradas

1. Safra (código).....1-**considerada**
2. Engenho (código).....desconsiderada
3. Lote (código).....desconsiderada
4. Variedade da cana (código).....**escolhida a mais significativa**
5. Estágio de maturação (código corte).....2-**considerada**
6. Idade do corte (em dias).....3-**considerada**
7. Época do plantio (dia/mês/ano).....3,4,5-**considerada**
8. Época do corte (dia/mês/ano).....6,7,8-**considerada**
9. Topografia (código).....desconsiderada
10. Tipo do solo (código).....9-**considerada**
11. Compactação do solo (código).....não fornecida / não considerada
12. Tempo médio de transporte (horas)..... não fornecida / não considerada
13. Área (há).....desconsiderada

Saídas

14. PCC (médio).....1-**considerada**
15. TCH (médio).....2-**considerada**
16. Fibra (médio).....3-**considerada**

3. Simulações

Após a incorporação de todo conhecimento heurístico na modelagem do problema, pré-processamento dos dados, iniciamos as simulações (treinamento e execução da RNA). Para isto foi usado o algoritmo de retro-propagação do erro (*error back-propagation*) [Werbos74] [Rumelhart86].

Na tentativa de se obter melhores resultados, utilizamos a técnica de planejamento fatorial [Barros95] dos treinamentos a fim de garantir a melhor topologia de rede para o problema utilizando os dados disponíveis.

Iniciamos as simulações variando os seguintes parâmetros: n° de camadas escondidas, n° de neurônios nessas camadas, função de ativação, taxa de aprendizado e n° de ciclos. Selecionando os melhores conjuntos de parâmetros, intensificamos as simulações com variações mais próximas destes (vide).

A partir da modelagem do problema, descrito na seção 2.2, seguimos cinco enfoques:

Enfoque 0 – a predição considera diferentes safras e anos como fatores relevantes;

Enfoque 1 – a predição não considera safra e ano relevantes;

Enfoque 2 – a predição não considera safra, ano e dia como relevantes;

Enfoque 3 – a predição considera safras, mas não ano como relevante;

Enfoque 4 - a predição não considera dia e mês de plantio e dia, mês e ano de corte como relevantes.

Avaliamos o desempenho das simulações, pelos percentuais de acerto nas predições, obtendo os seguintes melhores resultados (ver Tabela 1), com as respectivas configurações de rede.

Configuração da Redes Neurais						Resultados das Simulações		
Experimentos	Entrada	Escondidas - Neurônios	Taxa de aprendizado	Função Ativação	Ciclos	PCC(%)	TCH(%)	Fibra(%)
Enfoque 0	38	1 -- 16	0,1	Logística	15000	95,62	76,06	92,52
Enfoque 1	33	1 -- 9	0,2	Logística	3000	94,44	77,24	91,89
Enfoque 2	29	1 -- 8	0,2	Logística	5000	94,59	78,07	92,14
Enfoque 3	36	1 -- 6 2 -- 3	0,1	Logística	10000	95,33	78,03	92,4
Enfoque 4	9	1 -- 9	0,2	Logística	5000	93,41	77,68	90,95

Tabela 1 – Configuração de Redes Neurais e melhores resultados das simulações

4. Resultados

Dentre os vários conjuntos de simulações, obtivemos resultados bastante interessantes para PCC e fibra, com mais de 95% e 92%, respectivamente, de acerto nas previsões. Apesar de obtermos uma confiabilidade um pouco abaixo de 80%, a predição calculada para o TCH, é bastante estimulante, pois mostra uma real melhoria nos valores anteriormente calculados. Veja o quadro comparativo das melhores predições deste trabalho (ver Tabela 2) em relação às publicadas anteriormente em [Buarque98]. Na tabela pode se observar ainda melhoria em todas saídas, e de forma bastante significativa, em relação ao TCH (mais de 50%).

Saídas	Novos Resultados(%)	[Buarque98] (%)	Melhora
PCC	95,62	95,33	0,30%
TCH	78,07	49,20	58,68%
Fibra	92,52	89,68	3,17%

Tabela 2 – Comparação de resultados e melhora incremental

Se considerarmos, entretanto, as configurações das redes, onde menos neurônios se traduzem em menos recursos computacionais (i.e. menos tempo de computação e espaço de armazenamento), juntamente com as três saídas em conjunto, calculando a média dos erros, conclui-se que a melhor configuração de rede é a do *Enfoque 3*, como mostrado abaixo :

Enfoque	Acertos médios ¹
Enfoque 3	88,59
Enfoque 2	88,27
Enfoque 0	88,07
Enfoque 1	87,86
Enfoque 4	87,35

Tabela 3 – Análise de desempenho dos enfoques investigados

Uma ressalva importante é que o critério de classificação de desempenho de redes (i.e. resultados de predição de todos os itens conjuntamente) pode ter relevâncias diferentes dependendo das demandas específicas de cada cenário industrial desejado. Ai, cabe a cada agente de decisão nas usinas, proceder a uma seleção heurística dados as predições do modelo.

¹ Os acertos médios foram calculados a partir da média de acerto das três saídas: $(PCC\% + TCH\% + Fibra\%) / 3$

5. Conclusão

Os resultados obtidos demonstram a real possibilidade de implementação de um sistema de suporte a decisão usando RNAs, já que o modelo utilizado prediz três fatores de produtividade importantes para a decisão de colheita de cana-de-açúcar (PCC, TCH e fibra). A utilização desta modelagem pode determinar uma melhor qualidade da matéria-prima e conseqüentemente, a produtividade. Certamente, esta melhoria pode aumentar os lucros nas usinas e facilitar as decisões dos gestores. Provavelmente, isto ainda pode reduzir o preço final dos produtos industrializados, aumentando as margens de lucro que por sua vez podem, contribuir para o desenvolvimento da atividade como um todo.

Os resultados experimentais obtidos sugerem que é possível a construção de uma ferramenta que implemente e estenda o modelo utilizado neste trabalho para gerar curvas de maturação das variedades de cana-de-açúcar desejadas em vários cenários. Isto possibilitaria o agente de decisão conhecer o momento exato para a colheita de qualquer variedade cultivada em sua unidade. Inclusive considerando todos os efeitos extra-temporâneos, tais como seca, tratamentos culturais, pragas etc.

Finalmente, a solução ora apresentada e neste trabalho simulada, desde que treinada com dados histórico de produção local, pode ser aplicada às mais diversas regiões agrícolas do país. O que oferece uma flexibilidade interessante e necessária para unidade de produção instaladas em mais de uma região.

6. Referências

- [ALCOOLBrás04] Revista ALCOOLBrás Especial. Editora Valete, Edição 87 de Set/Out de 2004.
- [Alexander73] ALEXANDER, A.G. Sugarcane physiology: a comprehensive study of the Saccharum source-to-sink system. Amsterdam: Elsevier, 1973. 752p.
- [Barros95] Barros Neto, Benício, Scarminio, I. S., et Burns, E. E., "Planejamento e Otimização de Experimentos", Editora Unicamp, São Paulo, Brasil, 1995.
- [Buarque98] Buarque de Lima Neto, Fernando, "Suporte à Decisão de Colheita em cana-de-açúcar utilizando tecnologia Neural", Relatório Técnico RT-DI/UFPE /98 – Recife, Brasil, 1998.
- [Fu-Liu04] Li M. Fu and Casey S. Fu-Liu, "Multi-class cancer subtype classification based on gene expression signatures with reliability analysis", FEBS Letters, Volume 561, Issues 1-3, 12 March 2004, Pages 186-190.
- [Haykin94] Haykin, S., "Neural Networks – A Comprehensive Foundation", Prentice-Hall International Editions, NJ, USA, 1994.
- [Minsky69] Minsk, Marvin et Papert, Seymour, "Perceptrons", MIT Press, Cambridge-MA, USA, 1969.
- [Park04] S.J. Park, C.S. Hwang and P.L.G. Vlek, "Comparison of adaptive techniques to predict crop yield response under varying soil and land management conditions", Agricultural Systems, In Press, Corrected Proof, Available online 9 December 2004.
- [Rumelhart86] Rumelhart, D. E., et Hinton, G. E., et Williams, R. J., "Learning internal representations by erro propagation", in Rumelhart, D. E., et McClelland, J. L., (Editors), "Parallel Distributed Processing: Explorations in the Microstruture of Cognition", Vol. 1, pp.318-362, MIT Press, Cambridge – MA, USA, 1996.
- [Sinha98] P. Sinha, "A symmetry perceiving adaptive neural network and facial image recognition", Forensic Science International, Volume 98, Issues 1-2, 30 November 1998, Pages 67-89.
- [Werbos74] Werbos, Paul J., "Beyond regression: New tools for predicting and analysis in the behavioral sciences", Doctoral Dissertation, Applied Mathematics, Harvard University, USA, 1994.