

REDES NEURAIS PARA IDENTIFICAÇÃO DE PADRÕES NA DETECÇÃO DE QUEIMADAS NA FLORESTA AMAZÔNICA

Luiz Pinheiro Duarte NETO¹; Lauro Yasumasa NAKAYAMA²; Juliano João BAZZO³

¹ Bolsista PIBIC/CNPq; ² Orientador INPA/CPCR; ³ Co-orientador CPQD/UNICAMP

1. Introdução

O monitoramento de queimadas na região amazônica é de grande importância, devido à mesma ser uma das maiores florestas tropicais do planeta. Nos últimos anos, os incêndios florestais têm se tornando cada vez mais intensos em florestas da Amazônia, como impacto indiscutivelmente significativo, já que destroem árvores, reduzem a biomassa e modificam a estrutura original do ecossistema (BARBOSA, 2004). Embora vários métodos técnicos fossem testados, padrões de confiabilidade nunca foram suficientes para desenvolver um produto que seja adequado para o mercado. Alguns sistemas ópticos de sensoriamento remoto, muitas vezes implicam numa elevada taxa de alarme falso, devido à nuvens, à reflexão da luz, às atividades agrícolas e instalações industriais. Sistemas de sensores infra-vermelho testados na Espanha só podem detectar o fogo em si (STIPANICEV, 2006). No entanto, a fumaça é a característica relevante para o reconhecimento precoce de incêndios em áreas densamente arborizadas. Por isso, o uso de algoritmos inteligentes (RUSSEL, 2004), aplicados ao desenvolvimento de um sistema baseado em visão computacional (GONZALES, 2002), em tempo real vem a ser uma alternativa de grande importância para o reconhecimento de queimadas e fumaças e seu monitoramento (STIPANICEV, 2006). O algoritmo inteligente usado no trabalho foi desenvolvido com técnicas de reconhecimento de padrões aplicados a redes neurais artificiais. Reconhecimento de padrões é uma abordagem de pesquisa das redes neurais que tem por objetivo a classificação de objetos (padrões) em um número de categorias ou classes (THEODORIDIS, 1999). Uma rede neural artificial ou RNA é caracterizada por uma coleção massivamente paralela de unidades de processamento pequenas e simples, as interligações formam a maior parte da inteligência da rede (CARVALHO, 1998). Essas redes geram uma grande quantidade de processamento que pode ser empregada na identificação de padrões em uma analogia ao cérebro humano. Para que uma rede seja capaz de fazer o reconhecimento de padrões, inicialmente a estrutura da rede é treinada, ou seja, adquire conhecimento para adquirir os padrões almejados. Com o objetivo de detectar queimadas, foi desenvolvido um sistema de monitoramento em tempo real para o reconhecimento e prevenção de queimadas na floresta amazônica por meio de vídeo câmeras instaladas em torres de pesquisa do Instituto Nacional de Pesquisas da Amazônia – INPA.

2. Material e Método

O sistema para reconhecimento de queimadas teve como primeira abordagem a busca de imagens de incêndios em uma determinada região da Floresta Amazônica ocorrida nos últimos anos em Institutos de Pesquisa. A aquisição das imagens usadas se deu através de vídeo câmeras CCD em formato colorido RGB. A etapa seguinte foi desenvolver um banco de dados para que as imagens adquiridas pudessem ser armazenadas e acessadas de forma organizada (Figura 1). Nesta etapa as imagens armazenadas no banco de dados são pré-processadas por um algoritmo desenvolvido no *software* MATLAB que realiza a conversão dessas imagens para um formato binário para em seguida fazer a segmentação das imagens. Em posse dos dados processados pelo *software*, as imagens foram segmentadas, e em seguida foi extraída a região de interesse, que no caso são características de fumaças provenientes de incêndios florestais. O método utilizado para extrair as características das imagens foi a análise de componentes principais que usa técnicas de autovetores e autovalores. Esta técnica envolve um procedimento matemático que transforma um número de variáveis possivelmente correlacionadas em um número menor de variáveis não correlacionadas, chamado componentes principais (BAZZO, 2003). A proposta é reduzir a dimensão da representação dos dados tornando o processo de classificação ou tratamento destes mais flexível na recuperação da informação pontual da imagem significativa ao sistema. Com os dados reduzidos para uma nova dimensão foram projetadas três redes neurais (Figura 2) do tipo *Multi-Layer Perceptron* (MLP) que é uma arquitetura de múltiplas

camadas para o reconhecimento de imagens (HAYKIN, 2001). Sendo que cada rede é responsável por uma componente de cor: vermelho, verde e azul. Na criação das redes neurais para o reconhecimento de imagens, as mesmas foram divididas em três camadas, sendo 14 células sintética que representam os neurônios na camada de entrada, 10 neurônios na camada intermediária e 2 neurônios na camada de saída referentes imagens contendo fumaças e ruídos, a lógica utilizada para ativar os neurônios de saídas foi a lógica booleana, sendo o valor binário 0 para imagens contendo ruídos, tais como: nuvens, neblinas, etc; e o valor 1 para imagens que contenham apenas fumaça de incêndios. O número de neurônios determinados na camada de entrada foi obtido usando a técnica de Análise de Componente Principal – PCA. Os neurônios da camada escondida dependem do número de neurônios da camada de entrada e do tipo de aplicação da rede. Sendo assim, foram criados 10 neurônios na camada escondida. As três redes neurais foram criadas no *software* SNNS - *Stuttgart Neural Network Simulator*, que é um simulador interativo de redes neurais. Após a elaboração da estrutura das redes neurais e definidos seus parâmetros matemáticos, foram avaliadas 330 imagens de cada componente de cor: vermelho (*RED*), verde (*GREEN*) e azul (*BLUE*), totalizando 990 imagens referentes aos dados de treinamento e testes da rede neural. Sendo que 75% das imagens de cada componente serviram de treino e validação para a rede neural, o restante foi usado para testes. Os padrões de treinamento e testes foram gerados utilizando um algoritmo desenvolvido no *software* MATLAB, e assim criando ao total 990 arquivos no formato "PAT" para ser usado como dados de entrada da rede neural artificial elaborado no *software* SNNS.

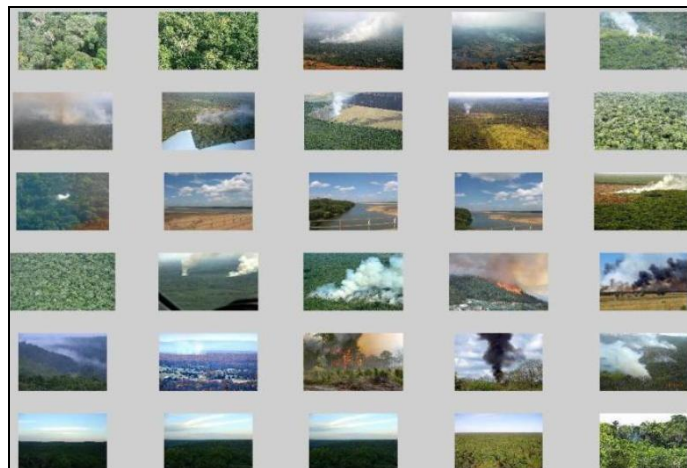


Figura 1 - Algumas imagens usadas no projeto.

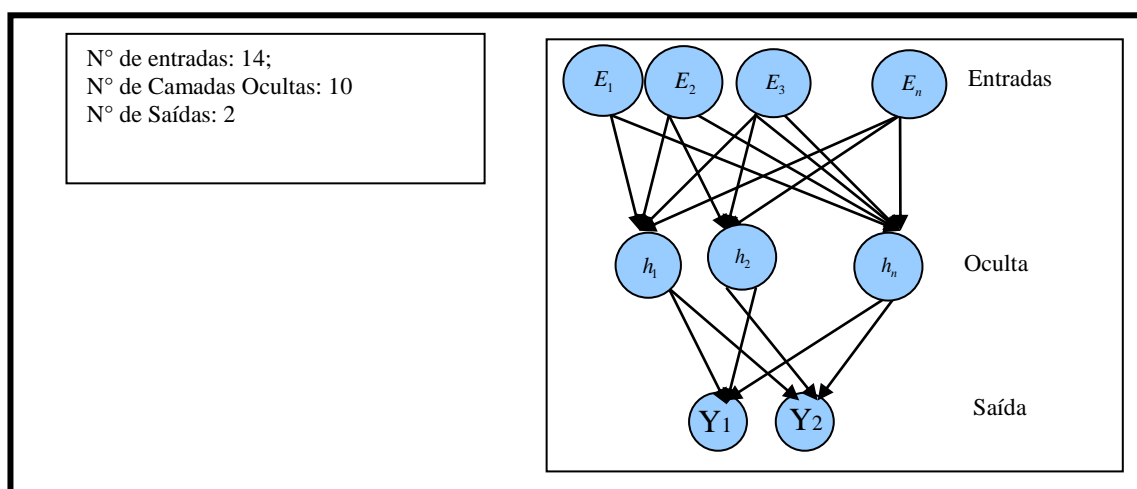


Figura 2 - Arquitetura da Rede Neural proposta.

3. Resultado e Discussões

Após um longo período de treinamento, pode se analisar o gráfico de erro. Os gráficos mostrados abaixo representam o erro de cada componente das imagens treinadas. O eixo y representa o nível de erro de aprendizagem da rede neural, ou seja, quanto menor o erro melhor o treinamento. O eixo x representa a quantidade de tempo do treinamento. Após o treinamento de cada componente e sua análise do gráfico, um conjunto de 80 padrões de imagens de teste são inseridos na entrada da rede neural e assim verificados se a rede conseguiu reconhecer os padrões almejados. Cerca de metade das imagens testadas eram de incêndio. A Tabela 1 mostra a porcentagem que a Rede Neural alcançou na fase de testes para cada componente de cor. Durante 2 horas de treinamento para a componente vermelha a rede neural alcançou um bom resultado. O gráfico mostra a curva de erro nesse período de tempo (Figura 3).




Figura 3 - Gráfico de Erro da Rede Neural com 2 horas de treinamento para a componente vermelha. Alcançando 75% de acertos.

Durante 2 horas de treinamento para a componente verde a rede neural não alcançou um bom desempenho na fase de treinamento, isso se deve ao fato da coloração verde ter destacado as florestas das imagens. O gráfico mostra a curva de erro nesse período de tempo (Figura 4).




Figura 4 - Gráfico de Erro da Rede Neural com 2 horas de treinamento para a componente verde. Alcançando 32% de acertos.

Como a componente verde, a rede neural para componente azul não alcançou um bom resultado. O gráfico mostra a curva de erro nesse período de tempo (Figura 5).




Figura 5 - Gráfico de Erro da Rede Neural com 2 horas de treinamento para a componente azul. Alcançando 28% de acertos.

Tabela 1 - Resultado final com a porcentagem que a Rede Neural alcançou nos testes.

Componentes	Acertos(%)	Erros(%)
Componente Vermelha	72	28
Componente Verde	32	68
Componente Azul	28	72

4. Conclusões

Nos tempos atuais onde a preocupação com o meio ambiente é crescente faz-se necessário a criação de um sistema que possa detectar os incêndios florestais de forma mais rápida e eficiente. Os resultados apresentados nesse artigo ainda não são conclusivos, porém mostram uma boa expectativa no uso dessa técnica baseada em PCA e Redes Neurais. Um dos trabalhos futuros será aplicar uma combinação linear dos valores dos neurônios para cada componente de cor e assim buscar melhorar o percentual de acertos para a detecção de incêndios nas florestas.

5. Referência

- BARBOSA, R.I; XAUD, M.R; SILVA, G..F.N; CATTÂNEO, A.C. (2004). **Cinzas na Amazônia: incêndios florestais reencontram Roraima**. Ciência Hoje 35 (207): 22-27.
- BAZZO, Juliano João. **Reconhecimento de Ações Faciais Através das Wallets de Gabor e Análise de Componente Principais**. 2003. Dissertação de Mestrado. Universidade Federal do Paraná, UFPR, Brasil.
- CARVALHO, André Carlos Ponce de Leon Ferreira de. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: DCC/IM, COPPE/Sistemas, NCE/UFRJ, (1998).
- GONZALES, Rafael. WOOD, Richard E. **Digital Image Processing**. 2 Ed. New Jersey: Prentice Hall, (2002).
- HAYKIN, Simon. **Redes Neurais: Princípios e prática**. Tradução Paulo Martins Engel. – 2.ed. – Porto Alegre: Bookman, (2001).
- RIPLEY, Brian D. **Pattern recognition and neural networks**. Melbourne: Cambridge University Press, (1997).
- STIPANICEV, Darko. VUKO, Tomislav. KRSTINIC, Damir. TULA, Maja. BODRO, Ljiljana. **"Forest Fire Protection by Advanced Video Detection System – Crotation Experiences"**. Split, Croácia, 2006.
- THEODORIDIS, Sergios. **Pattern Recognition**. Academic Press, USA, 1st edition, 1999 V. Cappellini. L, Mattii. A, Mecocci. **"An Intelligent System For Automatic Fire Detection in Forests"**. Florence, Italy: IEEE Xplore, 1989.