

Tecnologias em Sistemas de Segurança

André Luiz Silva de Castro¹

¹Universidade Federal do Mato Grosso do Sul (UFMS)
Corumbá – MS – Brasil

{andre.castro}@aluno.ufms.br

Abstract. *This article describes useful technologies in security systems that seeks to identify hazardous positions and trigger an alarm with pre-classified gestures. It was implemented mathematical models to classify the images obtained with the kinect sensor, and the initial results of this research were promising, and showed that the Kinect junction with Artificial Neural Networks can be efficient in classifying different positions in real time with a low computational cost.*

Resumo. *Este artigo descreve tecnologias úteis em sistemas de segurança que busca identificar posições de perigo e acionar um alarme com gestos pré classificados. Foi implementado modelos matemáticos para classificar as imagens obtidas com o sensor kinect, sendo que os resultados iniciais desta pesquisa foram promissores, e mostraram que, a junção do Kinect com as Redes Neurais Artificiais podem ser eficientes em classificar diferentes posições em tempo real com um baixo custo computacional.*

Palavras-chave - Redes Neurais Artificiais, Kinect

1. Introdução

O avanço da tecnologia nas últimas décadas vem possibilitando grandes avanços tecnológicos, impactando diretamente na segurança e comodidade da vida humana [Oliveira and Simões 2017]. Sua presença pode ser encontrada desde recreação ao trabalho, abrindo possibilidades para explorar novas ideias e aplicações.

O sensor kinect foi projetado para identificar os membros humanos com a finalidade de substituir o controle de video-game, e junto com uma técnica de classificação que pode ser utilizada para identificar movimentos ou posições que manifestem situações de insegurança, sendo uma boa opção para monitorar ambientes como visto em [Haykin 2007] [Silva et al. 2010].

Os trabalhos [Patsadu et al. 2012] [Correa et al. 2012] apresentaram importantes resultados utilizando RNAs em conjunto com o kinect, sendo que [Patsadu et al. 2012] afirma que obteve seus melhores resultados utilizando classificadores denominados de Suport Vectors Machine (SVM).

O objetivo geral deste trabalho consiste em dissertar sobre tecnologias que podem ser aplicadas a sistemas de segurança, apresentando um breve histórico e definições sobre as Redes Neurais Artificiais (RNA) seguido de alguns trabalhos que recorrem ao kinect. O objetivo específico investiga a dependência da generalização obtida com diferentes arquiteturas de RNA e o tamanho da amostra utiliza no treinamento. Foi projetado

um algoritmo em C# compatível com o Kinect para monitorar pessoas em um ambiente fechado classificando posições de perigo em tempo real.

Este artigo realiza uma breve introdução sobre RNA, Kinect aplicado em sistemas de segurança, segue com uma descrição dos principais conceitos e trabalhos relacionados, por fim apresenta os métodos utilizados, resultados e conclusões.

2. Suporte Tecnológico para Sistemas de Segurança

Redes Neurais Artificiais são modelos matemáticos auto-ajustáveis inspirados no processamento de informações visto nos neurônios. Segundo [Haykin 2007, p.28] uma rede neural, é um processador maciçamente distribuído, constituído de unidades de processamento simples que armazenam o conhecimento experimental e o torna disponível para uso [Silva et al. 2010].

As primeiras informações sobre a criação de RNAs foram apresentadas em 1943 pelo neuroanatomista e psiquiatra Warren McCulloch e matemático Walter Pitt. Em 1948 Wiener publica o livro *Cybernetics* que descreve o aprendizado como as constantes adaptações que ocorrem no cérebro. O Perceptron é um modelo matemático que representa um neurônio com a função de ativação não linear [Haykin 2007].

As primeiras informações sobre a criação de RNAs foram apresentadas em 1943 no artigo “Neurônios Formais” do neuroanatomista e psiquiatra Warren McCulloch e do matemático Walter Pitt em 1943, mostrando um modelo cognitivo com unidades sensoriais conectadas a uma única camada de neurônios, e demonstrou que se adicionada sinapses ajustáveis, a RNA de Warren McCulloch e Pitts pode ser treinada para classificar padrões em classes linearmente separáveis. Em 1960 Widrow e Hoff apresentaram o algoritmo de treinamento com o erro quadrático médio culminando na regra delta de aprendizagem.

A equação 1 define o valor que é inserido na função de ativação do perceptron $\varphi(v)$ com n entradas, (1) $v = \sum_n^i \varpi_i x_i + b$, onde ϖ_i é o peso sináptico para a entrada x_i e o bias b é um parâmetro livre. O ajuste dos pesos e bias pode ser representado pelas equações (2) $w(t+1) = \varpi_i(t) + a e_i x_i$ e (3) $b(t+1) = b(t) + a e$, onde e representa a diferença $e = \varphi_d - \varphi_0$ entre a saída desejada φ_d e obtida φ_0 .

O Adaline possui a função de ativação linear, e ajusta os pesos sinápticos utilizando a regra Delta para minimizar a média dos erros após cada padrão apresentado [Haykin 2007]. O Perceptron de Multicamadas (MLP) é uma evolução do perceptron com mais camadas de neurônios, e utiliza o algoritmo de treinamento backpropagation, para mais detalhes ver [Haykin 2007, p.183].

Os sistemas de segurança *indoor* fazem vigilância residenciais em locais fechados. [Ghose et al. 2013] propõe a utilização do Kinect para vigilância de casas monitorando diferentes pessoas através de padrões obtidos a partir do skeleton do Kinect. O sistema apresentado por [GUIMARÃES 2016] utiliza o Kinect para reconhecimento facial em tempo real, salvando em um banco de dados o “mapa” facial de cada pessoa.

O artigo de [CRUZ 2017] relata a instalação de um sistema inteligente de segurança da *intelbras*, e mostra que é possível controlar até 50 dispositivos DVRs (gravador de vídeo digital), NVRs (gravadores de vídeo em rede) ou câmeras IP (câmeras de transmissão pela internet) ao mesmo tempo com total segurança e rapidez. O gerenci-

amento local ou remoto permite a emissão de relatórios de eventos, controle de alarme, conexão com agências de segurança e emergência, etc.

3. Metodologia, Resultados e Conclusão

Foi implementado um algoritmo para coletar amostras, treinar classificadores e monitorar as imagens obtidas com o kinect em tempo real. O algoritmo coleta amostras das coordenadas cartesianas referente as posições das mãos, pulsos, braços, cotovelos, ombros, quadril e cabeça, e cada ponto é representado por 3 números (largura, profundidade e altura).

Como visto acima, existem diferentes métodos para classificação de padrões, e para diferenciar se as mãos estão para cima ou para baixo, foi escolhido o Perceptron e Perceptron de Multicamadas com a função de ativação Sigmoide, e um classificador *Support Vectors Machine*.

Tabela 1. Porcentagem de acertos obtidos para 5 arquiteturas de RNA com treinamento limitado em 8000 épocas

arquitetura	10 amostras	20 amostras	40 amostras	50 amostras
1	20%	50%	50%	60%
2	60%	90%	90%	80%
3	40%	30%	80%	80%
4	60%	70%	80%	80%
5	30%	30%	30%	90%

A tabela 1 mostra a generalização dos testes realizados para cada arquitetura de uma Rede Neural Artificial, seguindo a respectiva ordem, Perceptron (1), Perceptron de Camada Única com 5 neurônios (2), Perceptron de Camada Única com 10 neurônios(3), Múltiplo Perceptron de duas camadas com 5 neurônios(4), Múltiplo Perceptron de duas camadas com 10 neurônios (5).

Os testes iniciais desta pesquisa investigaram a eficiência para diferentes tamanhos de amostras no treinamento e quantidade de neurônios em suas camadas, por fim mensurou sua generalização para uma quantidade de amostras do mesmo tamanho e não vista no treinamento.

No treinamento foi utilizado um conjunto de 10,20,40,50 amostras com 13 pontos para definir os membros do corpo, que foram separadas em duas classes diferentes definidas a partir da altura das mãos. Dessa forma, as Redes Neurais Artificiais construídas são compostas de 39 entradas e duas saídas.

Pode-se observar na tabela 1 que a generalização é afetada pela quantidade de amostras no treinamento, e o Perceptron não obteve mais que 60 por cento de acerto, isso pode ser justificado pela função de ativação não linear e baixa quantidade de amostras no treinamento para um conjunto grande de entradas nem sempre linearmente separáveis.

Não esperava-se melhores resultados obtidos com o Perceptron em relação arquitetura (2) como visto para 20 amostras de treinamento, bem como, para a arquitetura (5) com treinamento de 20 e 40 amostras, esse resultado foi atribuído a qualidade das amostras utilizadas nesse treinamento.

Observa-se que arquitetura (5) possui um resultado ruim com menos de 40 amostras, contudo teve uma diferença significativa com 50 amostras no treinamento, obtendo um resultado igual arquitetura (2) que consiste na maior generalização obtida nesta pesquisa.

Pode-se afirmar que entre as diferentes arquitetura investigadas, o melhor resultado foi obtido com arquitetura (2), perdendo simplesmente para a arquitetura (5) com 50 amostras de treinamento.

O classificador SVM foi treinado com o mesmo objetivo que as RNA (classificar mãos para cima e para baixo respectivamente), recorrendo a 13 pontos, 39 entradas, e mesma quantidade de amostras que as Redes Neurais Artificiais, e o melhor resultado generalizou 80% para amostras não vista no treinamento.

Esses resultados são preliminares e serviram para investigar a generalização em função da quantidade de amostras utilizadas no treinamento de diferentes arquiteturas de RNA. E vale ressaltar que o kinect é uma tecnologia descontinuada e foi utilizado por conveniência, visto que a faculdade de Sistemas de Informação disponibilizou um e existiu uma vasta literatura a respeito com bons resultados.

Pode-se concluir que a quantidade de pontos e amostras são fundamentais para o desempenho da RNA e que a função de propagação Sigmoide teve o melhor resultado em relação a generalização para as amostras testes e tempo de convergência do treinamento das RNAs, por outro lado o classificador SVM teve o melhor desempenho em tempo de convergência em sua classificação. Pretende-se com trabalhos futuros aperfeiçoar a Rede Neural Artificial, realizando um tratamento mais rigoroso com as amostras, acrescentar mais duas posições para serem classificadas, e utilizar no treinamento a partir de 300 amostras.

Referências

- Correa, D. S. O., Sciotti, D. F., Prado, M. G., Sales, D. O., Wolf, D. F., and Osorio, F. S. (2012). Mobile robots navigation in indoor environments using kinect sensor. In *2012 Second Brazilian Conference on Critical Embedded Systems*, pages 36–41. IEEE.
- CRUZ, F. C. D. (2017). Proposta de projeto sistema de segurança eletrônica. *REPOSITÓRIO DE RELATÓRIOS-Engenharia Elétrica*, (1).
- Ghose, A., Chakravarty, K., Agrawal, A. K., and Ahmed, N. (2013). Unobtrusive indoor surveillance of patients at home using multiple kinect sensors. In *Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems*, page 40. ACM.
- GUIMARÃES, R. M. (2016). Desenvolvimento de um protótipo de software de reconhecimento facial de tempo real para registro eletrônico de ponto em ambientes indoor com utilização do dispositivo kinect. *Projetos e Dissertações em Sistemas de Informação e Gestão do Conhecimento*, 4(1).
- Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.
- Oliveira, F. d. T. and Simões, W. L. (2017). A indústria 4.0 e a produção no contexto dos estudantes da engenharia. In *Simpósio de engenharia de produção*.

- Patsadu, O., Nukoolkit, C., and Watanapa, B. (2012). Human gesture recognition using kinect camera. In *Computer Science and Software Engineering (JCSSE), 2012 International Joint Conference on*, pages 28–32. IEEE.
- Silva, I. d., Spatti, D. H., and Flauzino, R. A. (2010). Redes neurais artificiais para engenharia e ciências aplicadas. *São Paulo: Artliber*, 23(5):33–111.