

SISTEMA INTELIGENTE PARA DETECÇÃO DE IMPACTO EM PARTIDAS DE AIRSOFT USANDO MÁQUINAS DE VETORES DE SUPORTE E REDES NEURAIAS ARTIFICIAIS

NILMAR DE SOUZA*, LUCAS DE ARAUJO WANDERLEY ROMERO*, RAIMUNDO MENEZES*, AYDIN JADIDI*, ANTONIO CEZAR DE CASTRO LIMA*

**Escola Politécnica, Universidade Federal da Bahia
Rua Aristides Novis, Salvador, Bahia, Brasil*

Emails: nilmarufrb@gmail.com, lucas_romeiro@hotmail.com, raimundo.menezes@gmail.com, aydin.jadidi@gmail.com, acdcl@ufba.br

Abstract— Airsoft is a sport in which two teams simulate combat. The guns are replicas of firearms on 1: 1 scale and the projectiles are plastic balls. Since the projectiles don't leave any mark, there is no way to detect a hit unless the players who got shot raise their hands. The Airsoft clubs have it necessary to develop a method to detect the hits and avoid the problems caused by the lack of honesty among the players. This paper presents a strategy for the data acquisition and recognition of the hit impact of the projectiles of the Airsoft gun. The hardware National Instruments NI cDAQ 9172, with module NI 9205 was connected to the vest for data acquisition. The data was analyzed in Matlab, where the impact signals are processed by a wavelet transform and then classified by an Artificial Neural Network (ANN) and a Support Vector Machine (SVM) optimized by Particle Swarm Optimization (PSO). The obtained results from the classifiers have been compared.

Keywords— Artificial Neural Networks, Median Filter, Particle Swarm Optimization, Support Vector Machine.

Resumo— O Airsoft é um esporte no qual duas equipes simulam combate. Os equipamentos utilizados são réplicas em escala 1:1 de armas de fogo e os projéteis são esferas plásticas. Uma vez que os projéteis não deixam marca, não há como identificar quando um jogador é atingido a menos que ele levante a mão. Os clubes de Airsoft têm necessidade em desenvolver um método para detectar os jogadores atingidos e evitar os problemas causados pela falta de honestidade entre os jogadores. Este artigo apresenta uma estratégia para aquisição de dados e reconhecimento dos impactos do projéteis de arma de Airsoft. Para aquisição de dados um colete instrumentado foi conectado a um hardware National Instruments NI cDAQ 9172, com módulo NI 9205. Os dados foram analisados em Matlab, onde os sinais de impacto foram processados por uma transformada wavelet e classificados por uma Rede Neural Artificial (RNA) e máquinas de vetores de suporte (SVM) otimizadas por uma Particle Swarm Optimization (PSO). Os resultados obtidos a partir da classificação foram comparados e estão sendo apresentados.

Palavras-chave— Redes Neurais Artificiais, Filtro de mediana, Particle swarm optimization, Máquinas de Vetores de Suporte

1 Introdução

O Airsoft é um esporte que foi criado no Japão na década de 1970. O objetivo do jogo é eliminar os jogadores da equipe adversária, atirando neles. Os projéteis são esferas plásticas de 6 mm de diâmetro e as armas são simulacros em escala 1:1 de armas de fogo. Atualmente, a única maneira de detectar que houve um impacto é quando o jogador se declara levantando a mão. Em muitos casos, o jogador não percebe ou não declara que foi atingido e continua jogando. Esses jogadores são chamados de Highlanders. A existência desse perfil de jogador criou a necessidade de um dispositivo que identifica os jogadores atingidos.

Dessa forma, o objetivo geral do presente trabalho é desenvolver um dispositivo que reconheça quando um jogador é atingido por um projétil. Para reconhecer os impactos dos projéteis, é necessário implementar uma estratégia que use algumas das propriedades físicas do fenômeno. Assim, transdutores piezelétricos são implantados no colete para detectar os impactos em tempo real. Para tornar viável a captação dos dados

sem prejudicar a jogabilidade um colete deve ser adaptado. Somado a isso deve-se definir um sistema de aquisição de dados e uma estratégia de pré-processamento, extração de características e classificação. Diversos estudos foram realizados com o objetivo de reconhecer o impacto por meio de RNAs, SVMs e Lógica Fuzzy (FL) (ITO, 1997; TONG, TSO and XU, 2006; TONG, TSO and HUNG, 2006; TONG et al., 2008; LUK et al., 2009; LUK et al., 2010; LIU et al., 2011; BASTARI et al., 2011). A análise desses estudos possibilita o desenvolvimento de uma metodologia com maior pontencial para acertos.

Neste contexto, a proposta deste trabalho é apresentar um colete instrumentado que reconhece o impacto do projétil de Airsoft através dos transdutores. Um filtro de mediana implementado em um microcontrolador embarcado no colete é utilizado para detecção de eventos impulsivos. Uma transformada Wavelet é aplicada para a extração das características. Uma Rede Neural Artificial (RNA) e uma Máquina de Vetor de Suporte (SVM) são empregadas para classificar os sinais de impacto e em seguida a precisão dos clas-

sificadores na detecção das colisões é comparada.

Na primeira seção são apresentadas as motivações para o desenvolvimento do presente trabalho. Na segunda seção estão sendo indicados artigos relacionados que direcionam possibilidades de solução. Na terceira seção está sendo apresentado o procedimento metodológico adotado para solucionar o problema exposto. A quarta seção é destinada a mostrar os experimentos realizados e os resultados obtidos e na quinta seção está a conclusão do trabalho.

2 Trabalhos Relacionados

O reconhecimento de impacto consiste em identificar a colisão entre o projétil e o colete, bem como a propagação da onda detectada pelos transdutores. Para cada tipo de colisão e propagação, existe uma assinatura específica que pode ser usada para classificação. Ito e Uomoto (1997) apresentaram uma forte relação entre o impacto acústico e a vibração na superfície do concreto, a partir disso foi possível estabelecer uma relação entre as fissuras na superfície e a frequência de ressonância do impacto acústico (ITO, 1997). Tong *et al* (2006) realizaram inspeção no domínio do tempo utilizando a Densidade Espectral de Potência (PSD) dos sinais de impacto como entrada para classificação por meio de uma Rede Neural Artificial (RNA) (TONG, TSO and XU, 2006). Em outro estudo, Tong *et al* (2006) utilizaram a frequência do sinal como característica para classificação, os vetores de característica foram extraídos usando análise de componentes principais (PCA) e uma RNA multilayer back-propagation foi usada para classificação (TONG, TSO and HUNG, 2006). Em um trabalho posterior, Tong *et al* (2008) propõem a utilização de uma Least Squares Support Vector Machine (LS-SVM) para classificação, comparando os resultados com os do classificador de RNA (TONG *et al.*, 2008).

Luk *et al* (2009) afirmam que o ruído do áudio pode afetar a distribuição de energia do espectro do sinal adquirido, neste caso, o PSD não é suficiente e propõe uma avaliação baseada na decomposição Wavelet e uma Rede Neural Artificial para classificação (LUK *et al.*, 2009). Liu *et al* (2011) realizam uma abordagem usando um algoritmo de extração de frequência fundamental e aplicando a lógica fuzzy para estimar os vazios abaixo dos ladrilhos (LIU *et al.*, 2011). Bastari *et al* (2011) apresenta um método inovador para o dimensionamento de partículas de poeira transportadas pelo ar, aplicando técnicas de processamento de sinais aos dados de emissão acústica produzidos pelo impacto de partículas em superfícies metálicas. A transformada wavelet foi usada na extração de características e uma rede neural para mapear o vetor característico para a distribuição de tamanho de partícula (BASTARI *et al.*, 2011).

Os mecanismos eletrônicos de detecção de impacto foram utilizados com sucesso no Taekwondo. O uso do Electronic Body Protector (EBP) é aceito internacionalmente por várias organizações relacionadas a este esporte, incluindo a Federação Mundial de Taekwondo (DEL VECCHIO *et al.*, 2011)(FEDERATION, 2015). A intensidade do golpe é medida para diferentes categorias de peso e idade. Assim, para ganhar pontos, é necessário que o golpe atinja um limite pré-definido.

3 Metodologia

Para obter um produto que identifique os jogadores atingidos é necessário desenvolver uma estratégia de pré-processamento que valorize as características marcantes do fenômeno analisado, além disso prioriza-se a aplicação de técnicas que reduzam o tempo de processamento. Uma vez que os sinais de entrada forem tratados optou-se por utilizar classificadores para determinar quando um jogador foi atingido ou não.

Para o pré-processamento de sinais impulsivos, usualmente aplica-se o filtro de mediana, ou o filtro de mediana condicional (CHEN, 2002; KAUPPINEN, 2002). O filtro de mediana é um operador não linear, amplamente utilizado na remoção de ruído impulsivo em imagens (EMBREE, 1991). Este é um filtro no qual o valor do sinal em uma determinada posição é substituído pela mediana dos valores de um determinado número de amostras vizinhas da posição atual. Recomenda-se que a janela de amostra para o cálculo mediano contenha o dobro do tempo do evento, uma vez que o operador mediano tem a propriedade de remover picos com duração menor que metade do tamanho da janela (DUFAUX, 2001).

3.1 Extração de Características

Para todos os sistemas físicos, há um número infinito de peculiaridades que podem ser usadas para reconhecimento de padrões. Nessa etapa do reconhecimento, ocorre a seleção de informações importantes do objeto em estudo e, conseqüentemente, há uma redução no número de características. Sabendo que o sinal apresenta comportamento não estacionário, foi utilizada a Transformada Wavelet. O recurso de aproximação da transformada wavelet o torna adequado para análise de sinal não estacionário (WEI *et al.*, 2015). Esse comportamento é importante em sistemas que precisam detectar pequenas alterações de comportamento. A Transformada Wavelet pode ser vista como uma técnica de janela com tamanho de janela variável, que permite a avaliação de um sinal em análise no espaço tempo x frequência. Pois as janelas estão adotando uma função base, chamada wavelet mãe (REIGOTA, 2007).

Eles têm uma vantagem sobre os métodos tradicionais de Fourier na análise de situações que contêm descontinuidades e picos. A análise wavelet consiste em coeficientes de aproximação e detalhe. As aproximações representam os componentes de baixa frequência do sinal. Os coeficientes de detalhe são os componentes de alta frequência. Em geral, as informações de baixa frequência são as mais importantes. Este é um processo iterativo, sendo que o fator de aproximação é a entrada para a próxima iteração, na qual novos coeficientes de aproximação e detalhe são encontrados (LAHMIRI, 2014). Este processo ocorre recursivamente até o n^o nível de decomposição. Existem vários tipos de wavelet citados na literatura. O uso de cada um deles está associado ao seu aplicativo. É possível gerar uma infinidade de diferentes wavelets e, particularmente, construir um conjunto de wavelets adequados para processar um tipo de sinal específico (SILVA, 2007). Exemplos de funções conhecidas incluem Haar, Morlet e Daubechies.

3.2 Classificação

Nesta etapa, os dados de entrada já processados são classificados. Essa classificação consiste em associar um objeto a uma determinada classe, entre os vários que se apresentam. Assim, o classificador aprende a diferenciar entre as diferentes classes às quais um determinado objeto pertence. Para o presente trabalho, foi desenvolvida uma comparação entre o uso de um RNA Multilayer Perceptron (MLP) e um SVM.

3.2.1 Redes Neurais Artificiais

Uma RNA é formada por várias unidades de processamento (nós), que são unidas por conexões, às quais são atribuídos pesos. Os nós executam operações em seus dados de entrada e os enviam para as próximas camadas. O comportamento inteligente da rede tem origem nas interações entre essas unidades (GRIFFIN, 2016). A maioria dos modelos de redes neurais é composta de algumas regras de treinamento, que alteram os pesos das conexões de acordo com os elementos de entrada. A característica mais importante das redes neurais é a sua capacidade de aprendizagem. O que acontece com a adaptação de seus pesos, conhecida como estágio de treinamento. A aprendizagem é concluída quando a rede adquire um grau de generalidade para um grupo de objetos. Existem vários algoritmos de aprendizagem específicos para cada modelo de rede neural, a principal diferença entre eles é como os pesos são ajustados. Para o presente estudo foi utilizado um aprendizado supervisionado com o algoritmo de treinamento backpropagation. Que trabalha pesquisando iterativamente a diferença mínima entre a saída obtida e a desejada, usando um erro mínimo como

referência. Portanto, os pesos são ajustados entre as camadas por meio da retropropagação do erro encontrado em cada iteração.

3.2.2 Support Vector Machine

As SVMs são classificadores que derivam da Teoria Estatística da Aprendizagem (SLT) proposta por Vapnick e Chervonenkis. O SLT estabelece condições matemáticas que auxiliam na escolha de um classificador em particular a partir de um conjunto de dados de treinamento. Essas condições levam em conta o desempenho do classificador no conjunto de treinamento e sua complexidade, a fim de obter um bom desempenho também para novos dados do mesmo domínio. Nos SVMs é procurada uma função que separe melhor os dados apresentados em um estágio de treinamento, sem prejudicar sua generalização. Supõe-se que os dados analisados são linearmente separáveis, classificando-os como -1 ou +1. Isto é possível construindo um hiperplano representado pela equação $w^t x + b = 0$ (onde "w" é o vetor de coeficientes do hiperplano, "b" corresponde a um termo bias). O hiperplano otimizado minimiza uma função de custo baseada em dois critérios: maximização de margem e minimização de erros. Sendo representado como $\phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i$ (onde "C" representa o custo de oportunidade entre a complexidade do modelo $\|w\|^2$ e a minimização dos erros de treinamento). Esse parâmetro de custo é importante para a generalização do hiperplano, portanto, a escolha correta desse parâmetro define o sucesso ou a falha do treinamento. Quando inicialmente proposto por Vapnick e colaboradores, as SVMs funcionavam apenas para um conjunto de dados linearmente separáveis. Para resolver este problema, as SVMs foram associadas à função kernel, que projeta os dados em um espaço de características de alta dimensão, permitindo a classificação em espaços separáveis não lineares. A escolha da função do kernel, bem como seus parâmetros, é importante para melhorar o desempenho das SVMs. A Função Base Radial (Radial Basis Function - RBF) é uma função kernel comum, sendo expressa da seguinte forma: $k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$. A seleção de parâmetros de custo e a função do kernel (γ para a função RBF) representam outro problema na aplicação das SVMs. Esta seleção pode ser realizada de forma exaustiva por meio de buscas em grade, ou a partir de algoritmos que apresentem um menor custo computacional.

3.2.3 Particle Swarm Optimaztion (PSO)

O PSO é um método de otimização baseado no comportamento social entre indivíduos (partículas). As partículas se movem no espaço n-dimensional. Cada partícula mantém um registro

da posição de seu melhor desempenho. Então, o melhor valor obtido por qualquer partícula na vizinhança até o momento é armazenado. E o melhor valor de todas as partículas é armazenado da melhor forma geral. Todas as partículas podem compartilhar informações sobre o espaço de pesquisa. Cada partícula calcula a velocidade de si mesma e atualiza a nova posição em cada iteração. A velocidade atual da d^a dimensão da i^a partícula no tempo t é (SHI, 1998):

$$v_{i,d}(t) = w \times v_{i,d}(t-1) + c_1 \times \text{rnd}() \times (p_{i,d} - x_{i,d}(t-1)) + c_2 \times \text{rnd}() \times (p_{g,d} - x_{i,d}(t-1)) \quad (1)$$

$$v_{i,d} \in [-v_{max}, v_{max}] \quad (2)$$

Na equação 2, $\text{rnd}()$ corresponde a um valor aleatório no intervalo $[0,1]$, as constantes positivas C_1 e C_2 são fatores de aprendizado e "w" é o peso inercial. Na fórmula inicialmente proposta por (JAMES, 1995) o peso é igual a 1 os coeficientes $c_1 = c_2 = 2$. A nova posição da partícula é calculada usando a seguinte Equação 3:

$$x_{i,d}(t+1) = x_{i,d}(t) + v_{i,d}(t+1) \quad (3)$$

4 Experimentos e Resultados

A primeira etapa foi o desenvolvimento de um colete no qual houvessem sensores capazes de captar a colisão dos projéteis. Em seguida foi necessário utilizar um sistema para aquisição dos dados com tempo de resposta e taxa de amostragem satisfatórios para o sucesso do projeto. Por fim, foram escolhidas as plataformas para aplicação das técnicas de processamento e classificação dos dados.

4.1 Protótipo

Para reconhecer o impacto, foi necessário desenvolver um colete com o qual seria possível monitorar o corpo do usuário sem prejudicar sua mobilidade e segurança. A maioria dos coletes usados nos jogos Airsoft tem a função de armazenar o equipamento do jogador e proteger o usuário. No entanto, o material com o qual estas jaquetas são feitas não é adequado para a aquisição dos sinais. Normalmente, o material usado para fazer o colete tem como objetivo amortecer o impacto do projétil, o que dificulta a coleta de dados de um tiro que atingiu o colete em uma região distante do sensor. Com este tipo de configuração, o sinal de impacto só seria detectado quando o projétil atingisse uma região próxima ao sensor. Um colete semelhante ao utilizado nos jogos da Airsoft foi desenvolvido, com a inclusão de uma tela de aço galvanizado entre as duas camadas de corano

e borracha sintética. Na aproximação da Figura 1 é possível observar a tela inserida entre as duas camadas de corano. Um transdutor piezoelétrico foi colocado em cada lado e fixado na região central da tela.



Figura 1: Protótipo do colete com uma aproximação na região de acesso aos transdutores.

4.2 Aquisição de dados

Os dados foram coletados em 20kHz utilizando um hardware da National Instruments NI cDAQ 9172, com módulo NI 9205. Como o colete é o mesmo utilizado nos airsoft clubs, foi possível realizar simulações de situações existentes nos jogos, como corrida, saltos, agachamento e queda.

No gráfico Figura 2 está sendo apresentado um sinal proveniente de um jogador que foi atingido por um tiro quando estava correndo. Na mesma imagem é apresentado um gráfico que expressa o resultado da aplicação do filtro de mediana. O sinal original está sendo apresentado em azul e a saída do filtro mediano está em vermelho. A partir do gráfico, observa-se que a saída do filtro acompanha o sinal original para sinais não impulsivos. No entanto, a partir da aproximação, que aparece na mesma figura, pode-se notar que há uma diferença entre o valor de saída do filtro e o valor do sinal original para o momento do impacto, deixando apenas parte da passagem do sinal impulsivo. A ideia é comparar o valor coletado com a mediana de uma janela com 10 elementos e verificar se esse valor é maior que um limiar pré-definido, se assim for, o sinal é caracterizado como impulsivo e potencialmente um tiro. Com os testes foi possível observar que dos eventos possíveis em uma partida de airsoft apenas tapas rápidos e fortes aplicados próximos ao sensor passaram pelo filtro de mediana, podendo ser confundidos com tiros. Depois de passar pelo filtro mediano, o vetor de entrada é reduzido por meio da transformada wavelet e, em seguida, o sinal é enviado para um classificador (RNA ou SVM).

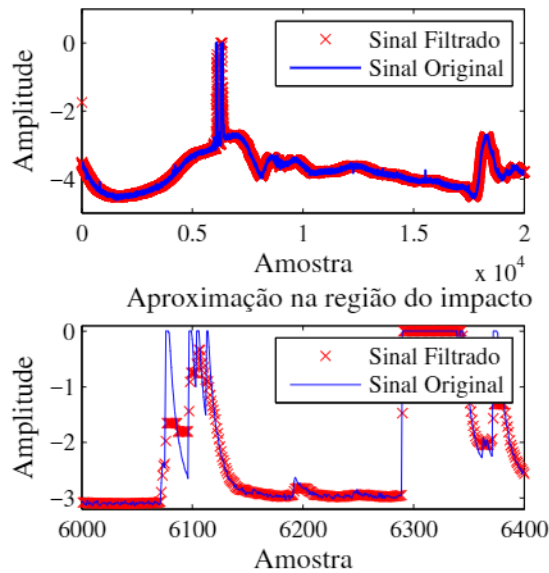


Figura 2: Resultado da aplicação do filtro de mediana em um sinal proveniente dos transdutores piezoelétricos da frente, indicando a região do impacto.

Inicialmente foram estudadas algumas características do impacto, tais como frequências prevalentes, amplitude, duração do evento. Tiros foram disparados com uma arma de Airsoft a uma distância de 5 m do alvo, no qual havia um tradutor piezoelétrico. Uma das amostras de tiro pode ser vista na Figura 3, onde o perfil de impacto e sua propagação são apresentados.

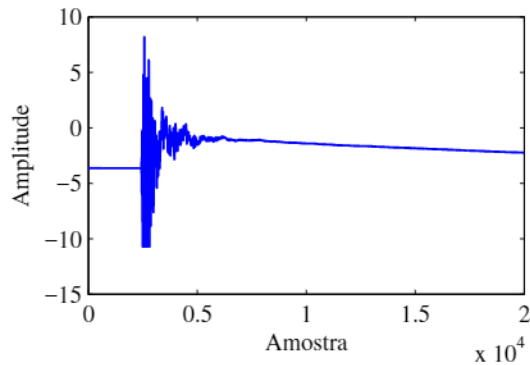


Figura 3: Sinal do impacto de um projétil disparado por um marcador de Airsoft

As principais características dos disparos são um impacto de curta duração seguido por um sinal oscilante com uma frequência dominante de 1 kHz sem variações significativas a partir de 3,5 kHz. Imediatamente após o impacto, há um aumento no nível do sinal que diminui à medida que se propaga. O evento tem uma duração média de 750 μ s. Essas características são importantes porque definem as especificidades do sinal de tiro e quais particularidades o diferenciam de outros eventos. Em

uma partida, o jogador está sujeito a vários movimentos como queda, salto, agachamento e corrida que ocasionam distúrbios que podem afetar os transdutores piezoelétricos, criando sinais que possivelmente podem ser confundidos com um tiro. Alguns deles foram catalogados e estudados para evitar confusão na classificação. Esses eventos criam um distúrbio no colete que não tem característica impulsiva, conseqüentemente, ao passar pelo filtro mediano eles são facilmente descartados. No entanto, alguns eventos simulados (como tapa), que não são comuns em partidas de airsoft, criam um distúrbio impulsivo semelhante ao de ser atingido e, portanto, merecem atenção especial. Na Figura 4 o sinal produzido pelo impacto de um tapa no colete está sendo apresentado. Visualmente, algumas diferenças podem ser observadas entre os sinais da Figura 3 e Figura 4. Essa diferença é repetida quando o sinal do tiro é comparado com os outros sinais coletados. Essas diferenças são importantes para o sucesso do classificador.




Figura 4: Sinal proveniente de um tapa

O sinal dos tapas usados contra o colete tem uma frequência dominante abaixo de 1 kHz. O tempo até que o sinal seja completamente dissipado é maior que nos disparos, o decaimento ocorre mais lentamente e a amplitude, em geral, é menor. Entretanto, o momento de impacto apresenta características semelhantes para os dois eventos, ambos de curta duração e alta amplitude. Devido a estas características do sinal impulsivo, alguns tapas passam através do filtro mediano. Depois de passar pelo filtro mediano, os coeficientes de aproximação do quarto nível da transformada wavelet são aplicados no sinal. A função base Daubechies foi utilizada como wavelet mãe, a escolha dessa wavelet foi baseada na análise do evento. Este tipo de wavelet mãe é adequado para forma de onda transitória e sem simetria (RAFIEE et al., 2009; MAREC et al., 2008). Uma vez escolhida a função wavelet base, os coeficientes de aproximação de quarto nível foram apresentados à rede neural. A função tangente sigmóide foi usada para ativar os neurônios na camada inter-

mediária e a função linear na camada de saída. Foi escolhido apenas uma camada oculta, com 9 neurônios, a escolha do número de neurônios foi baseada no menor valor do erro quadrático médio (RMSE), de acordo com a tabela 1.

Tabela 1: Erro quadrático médio para diferentes números de neurônios

Neurônios	RMSE
1	0,56
2	0,50
3	0,44
4	0,49
5	0,47
6	0,44
7	0,42
8	0,47
9	0,39
10	0,41
11	0,47
12	0,44
13	0,46
14	0,39
15	0,46
16	0,47
17	0,44
18	0,46
19	0,47

Buscando melhorar os resultados, foram realizados testes para encontrar as melhores daubechies e qual o melhor nível de abordagem. Mais uma vez, o erro quadrático médio é usado como critério para selecionar esses parâmetros. O resultado dos testes está sendo apresentado na Tabela 2

Analisando a tabela optou-se por utilizar daubechies "db4" até o terceiro nível, configuração que apresentou o menor erro quadrático médio. Depois de definir os parâmetros wavelet e a topologia de rede, 100 amostras foram usadas para treinamento e 100 amostras para teste e validação. Sob essas condições, houve uma taxa média de acertos de 95 % para amostras de teste e validação. Os mesmos dados apresentados à rede neural foram apresentados ao SVM, que teve seus parâmetros C e γ otimizados através da aplicação do PSO. O PSO tem como parâmetros iniciais 20 partículas, 100 iterações, velocidade mínima igual a -0,2 e velocidade máxima igual a 0,2. A atualização dos coeficientes C_1 e C_2 é realizada como proposto por (RATNAWEERA et al., 2004) e está sendo apresentado na Equação 4:

$$C_1 = (C_{1fim} - C_{1ini}) * (i/MaXiter) + C_{1ini}; \quad (4)$$

$$C_2 = (C_{2fim} - C_{2ini}) * (i/MaXiter) + C_{2ini};$$

A atualização de peso segue o modelo proposto

Tabela 2: Erro quadrático médio para diferentes Daubechies usando coeficientes de aproximação de vários níveis

Daubechies	Nível	RMSE
db2	4	0,44
db2	3	0,49
db2	2	0,47
db3	4	0,47
db3	3	0,46
db3	2	0,53
db4	4	0,42
db4	3	0,41
db4	2	0,42
db5	4	0,42
db5	3	0,46
db5	2	0,46
db6	4	0,44
db6	3	0,42
db6	2	0,53
db7	4	0,49
db7	3	0,47
db7	2	0,42
db8	4	0,41
db8	3	0,50
db8	2	0,55

por (CHATTERJEE, 2006)

$$W = \left(\frac{((Max_{iter} - i)^n)}{(Max_{iter})^n} * (W_{ini} - W_{fim}) \right) + W_{fim};$$

A partir desses parâmetros foram simulados várias vezes, encontrando alguns valores para C e γ . Na Tabela 3 é possível observar a relação entre C , γ e a precisão do sistema. Com estes parâmetros

Tabela 3: Acurácia para combinações de C e γ obtidos pelo PSO

C	γ	Acurácia
20000	0,9419	97,5
1	0,9506	96
652	0,9714	97,5
6416	0,6163	95
8003	0,9908	98,5

otimizados, o SVM foi testado e obteve-se uma taxa de acerto de 98,5 %, superando os 95,0 % obtidos com a aplicação de RNA.

5 Conclusão

Um grande problema para os clubes de Airsoft são os Highlanders. No presente trabalho foi apresentado um instrumento capaz de detectar impactos e reconhecer quando eles são oriundos de um projétil disparado por arma de Airsoft. A solução proposta no presente artigo pode ser comparada com os coletes usados para Taekwondo e Esgrima. O colete instrumentado, apresentado neste trabalho,

representa uma evolução para o Airsoft. Sua aplicação minimiza a possibilidade de ação dos Highlanders.

Para que fosse possível realizar o reconhecimento foi necessário promover uma adaptação nos coletes normalmente utilizados em partidas do jogo. As mudanças foram realizadas para facilitar a coleta de dados e manter a mobilidade dos jogadores. Outra etapa importante para o sucesso do projeto foi a escolha de um sistema de aquisição de dados, para isso optou-se por um hardware da National Instruments o NI cDAQ 9172, com módulo NI 9205 utilizando uma taxa de amostragem de 20 kHz.

Para o pré-processamento foi utilizado um filtro de mediana implementado no microcontrolador embarcado no colete. As etapas de processamento e classificação foram realizadas em Matlab e foram comparadas duas técnicas muito populares, Suport Vector Machines (SVMs) e Redes Neurais Artificiais (RNAs). A aplicação dos SVMs apresentou melhores resultados que as RNAs. Propõe-se para trabalhos futuros a implementação do classificador no microcontrolador embarcado no colete.

6 Agradecimentos

Agradeço à Fundação de Amparo à Pesquisa do Estado da Bahia por seu apoio financeiro, ao Centro de Capacitação Tecnológica em Automação Industrial (CTAI) pela disponibilização de laboratórios e equipamentos e Arena PaintBall pela parceria no projeto, cedendo materiais e espaço para os testes necessários.

Referências

- BASTARI, A., CRISTALLI, C., MORLACCHI, R. and POMPONI, E. (2011). Acoustic emissions for particle sizing of powders through signal processing techniques, *Mechanical Systems and Signal Processing* **25**(3): 901–916.
- CHATTERJEE, A.; SIARRY, P. (2006). Non-linear inertia weight variation for dynamic adaptation in particle swarm optimization, *Computers & Operations Research* **33**(3): 859–871.
- CHEN, T.; WU, H. R. (2002). Adaptive impulse detection using center-weighted median filters, *Signal Processing Letters, IEEE* **8**(1): 1–3.
- DEL VECCHIO, F., FRANCHINI, E., DEL VECCHIO, A. H. M. and PIETER, W. (2011). Energy absorbed by electronic body protectors from kicks in a taekwondo competition, *BIOLOGY OF SPORT* **28**(1): 75–78.
- DUFAUX, M. A. (2001). *Detection and recognition system for impulsive audio signals*, Docteur és sciences, Faculte des Sciences - Université de Neuchâtel, Neuchâtel - Suíça.
- EMBREE, P. M.; KIMBLE, B. (1991). *C Language Algorithms for Digital Signal Processing*, Prentice-Hall.
- FEDERATION, W. T. (2015). Competition rules and interpretation, <http://www.taekwondobond.nl/tbn/wp-content/uploads/2008/08/WTF-competition-rules-1-1-20151.pdf>. [Accessed on: 09/11/2016].
- GRIFFIN, J.; CHEN, X. (2016). Real-time simulation of neural network classifications from characteristics emitted by acoustic emission during horizontal single grit scratch tests, *Journal of Intelligent Manufacturing* **27**(3): 507–523.
- ITO, Y.; UOMOTO, T. (1997). Nondestructive testing method of concrete using impact acoustics, *NDT & E International* **30**(4): 217–222.
- JAMES, K.; RUSSELL, E. (1995). Particle swarm optimization, *Proceedings of 1995 IEEE International Conference on Neural Networks*, pp. 1942–1948.
- KAUPPINEN, I. (2002). Methods for detecting impulsive noise in speech and audio signals, *Digital Signal Processing, 2002. DSP 2002. 2002 14th International Conference on*, Vol. 2, IEEE, pp. 967–970.
- LAHMIRI, S. (2014). Wavelet low- and high-frequency components as features for predicting stock prices with backpropagation neural networks, *Journal of King Saud University – Computer and Information Sciences* **26**(2): 218–227.
- LIU, S. X., TONG, F., LUK, B. L. and LIU, K. P. (2011). Fuzzy pattern recognition of impact acoustic signals for nondestructive evaluation, *Sensors and Actuators A: Physical* **167**(2): 588–593.
- LUK, B. L., LIU, K. P., JIANG, Z. D. and TONG, F. (2009). Robotic impact-acoustics system for tile-wall bonding integrity inspection, *Mechatronics* **19**(8): 1251–1260.
- LUK, B. L., LIU, K. P., TONG, F. and MAN, K. F. (2010). Impact-acoustics inspection of tile-wall bonding integrity via wavelet transform and hidden markov models, *Journal of sound and vibration* **329**(10): 1954–1967.

- MAREC, A., THOMAS, J. H. and EL GUER-JOUMA, R. (2008). Damage characterization of polymer-based composite materials: Multivariable analysis and wavelet transform for clustering acoustic emission data, *Mechanical Systems and Signal Processing* **22**(6): 1441–1464.
- RAFIEE, J., TSE, P. W., HARIFI, A. and SA-DEGHI, M. H. (2009). A novel technique for selecting mother wavelet function using an intelligent fault diagnosis system, *Expert Systems with Applications* **36**(3): 4862–4875.
- RATNAWEERA, A., HALGAMUGE, S. K. and WATSON, H. C. (2004). Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients, *IEEE Transactions on evolutionary computation* **8**(3): 240–255.
- REIGOTA, N. S. (2007). *Comparação da transformada wavelet discreta e da transformada do cosseno, para compressão de imagens de impressão digital*, Mestrado em engenharia elétrica, Escola de Engenharia de São Carlos, da Universidade de São Paulo, São Carlos - SP.
- SHI, Y.; EBERHART, R. (1998). A modified particle swarm optimizer, *Evolutionary Computation Proceedings, 1998. IEEE World Congress on Computational Intelligence., The 1998 IEEE International Conference on*, IEEE, pp. 69–73.
- SILVA, C. Y. V. W. (2007). *Extração de características de imagens médicas utilizando wavelets para mineração de imagens e auxílio ao diagnóstico*, Mestrado em ciências - ciências da computação e matemática computacional, Instituto de Ciências Matemáticas e de Computação - ICMC-USP, São Carlos - SP.
- TONG, F., TSO, S. K. and HUNG, M. Y. Y. (2006). Impact-acoustics-based health monitoring of tile-wall bonding integrity using principal component analysis, *Journal of sound and vibration* **294**(1): 329–340.
- TONG, F., TSO, S. K. and XU, X. M. (2006). Tile-wall bonding integrity inspection based on time-domain features of impact acoustics, *Sensors and actuators A: Physical* **132**(2): 557–566.
- TONG, F., XU, X. M., LUK, B. L. and LIU, K. P. (2008). Evaluation of tile-wall bonding integrity based on impact acoustics and support vector machine, *Sensors and Actuators A: Physical* **144**(1): 97–104.
- WEI, Y., HAN, Z., TENG, R. and YUAN, Q. (2015). Noise analysis of truck crane drive axle by using continuous wavelet transform, *Proceedings of the 2015 International Conference on Intelligent Systems Research and Mechatronics Engineering*, 2015 International Conference on Intelligent Systems Research and Mechatronics Engineering (ISRME 2015), Atlantis Press, Zhengzhou, China, pp. 1–5.