

FACULDADE DE ENGENHARIA - FENG  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE  
MESTRADO EM ENGENHARIA ELÉTRICA

NICHOLAS KLUGE CORRÊA

**CLASSIFICAÇÃO DE MANOBRAS DE SKATE ATRAVÉS DE ACELEROMETRIA E REDES  
NEURAIS ARTIFICIAIS**

Porto Alegre  
2017

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica  
do Rio Grande do Sul

NICHOLAS KLUGE CORRÊA

**CLASSIFICAÇÃO DE MANOBRAS DE SKATE  
ATRAVÉS DE ACELEROMETRIA E REDES NEURAIS  
ARTIFICIAIS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, da Pontifícia Universidade Católica do Rio Grande do Sul, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Profa. Marlise Araujo dos Santos, Ph.D.

Porto Alegre  
2017

## Ficha Catalográfica

C825 Corrêa, Nicholas Kluge

Classificação de manobras de Skate através de acelerometria e redes neurais artificiais / Nicholas Kluge Corrêa . – 2017.

128 f.

Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, PUCRS.

Orientadora: Profa. Dra. Marlise Araujo dos Santos.

1. Skate. 2. Acelerometria. 3. Redes neurais artificiais. 4. Exergames. I. Araujo dos Santos, Marlise. II. Título.



Pontifícia Universidade Católica do Rio Grande do Sul  
FACULDADE DE ENGENHARIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE

## CLASSIFICAÇÃO DE MANOBRAS DE SKATE ATRAVÉS DE ACELEROMETRIA E REDES NEURAIS ARTIFICIAIS

**CANDIDATO: NICHOLAS KLUGE CORRÊA**

Esta Dissertação de Mestrado foi julgada para obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Pontifícia Universidade Católica do Rio Grande do Sul.

  
\_\_\_\_\_  
**DRA. MARLISE ARAÚJO DOS SANTOS - ORIENTADORA**

**BANCA EXAMINADORA**

  
\_\_\_\_\_  
**DR. DENIZAR ALBERTO DA SILVA MELO - DO PPGBCM, FABIO - PUCRS**

  
\_\_\_\_\_  
**DR. ALEXANDRE ROSA FRANCO - DO PPGE/FENG - PUCRS**

**PUCRS**

“Skate não é um hobby. E não é um esporte. Skate é uma maneira de aprender a redefinir o mundo ao seu redor. É uma maneira de sair de casa, se conectar com outras pessoas, e olhar para o mundo através de outros olhos.” – Ian MacKay

## AGRADECIMENTOS

Gostaria de agradecer primeiro lugar, a todas as pessoas que, de alguma forma ou de outra, me ajudaram no desenvolvimento deste projeto, e por toda minha vivência durante o programa do PPGEE.

Agradeço a Professora Thais Russomano, pela oportunidade e confiança em meu trabalho, e pela orientação que me foi concedida. E agradeço em especial a Professora Marlise do Santos Araujo cuja orientação me foi concedida durante a finalização deste projeto.

Agradeço toda a minha família, pelo apoio incondicional que sempre me foi disponibilizado, e em especial aos meus pais, Arthur Corrêa Junior e Fátima Rejane Kluge Corrêa, por terem confiado em mim e me deixado perseguir meus sonhos, e ao meu avô, Vinícius Dutra Kluge, por ter sido o primeiro indivíduo a me despertar a curiosidade e a vontade de resolver problemas.

A todos os amigos e amigas que conheci graças ao programa, colegas e companheiros de estudo, e especialmente aqueles que encontraram paciência e bondade em seus seres para me auxiliar durante as diversas etapas de formação que fui submetido, minha mais sincera gratidão a Luiza e Gustavo. Nunca houve falta de amizade, fraternidade e sensibilidade por parte dos integrantes do programa e seus responsáveis.

Agradeço a CAPES pelo auxílio financeiro disponibilizado, ao Prof. Júlio César de Lima e toda a equipe de pesquisadores do Centro de Microgravidade por terem me disponibilizado toda a ajuda que me foi necessária. Em respeito aos responsáveis do programa, meus sinceros agradecimentos ao Prof. Alexandre Franco e ao Prof. Dario de Azevedo, por terem me encatado com a beleza abstrata das ciências exatas, e aos funcionários responsáveis pelo atendimento dos alunos na secretária do PPGEE, muito obrigado pela paciência e zelo que tiveram por minha pessoa.

Agradeço a todos os skatistas que já me privilegiaram com sua presença e energia durante as inúmeras vivências dentro do Skate, agradeço aos meus alunos, a Escola ANDE de Skate, a SWELL, e a Yerbah Skate Shop onde apoio e auxílio nunca me foi negado. Gratidão ao Skate, cultura essa que possui em seus alicerces diversos valores essenciais para o desenvolvimento de um indivíduo saudável e um cidadão de bem.

Por fim, agradeço a minha namorada Bruna Franzon Bianchi, que pela graça, paciência, apoio, e incondicional afeto tornou esta jornada uma a qual eu fui capaz de suportar até o fim, obrigado por não ter me deixado desistir.

Gratidão.

## RESUMO

Skate é uma das culturas mais populares no Brasil, com mais de 8.5 milhões de adeptos. O movimento esportivo atualmente se encontra em uma fase de grande crescimento, dada inclusive a estréia da modalidade nos Jogos Olímpicos em Tóquio 2020.

O presente estudo teve como objetivo desenvolver técnicas de detecção e classificação de manobras de *Street Skate*, utilizando sensores inerciais IMU (*Inertial Module Unit*) e Redes Neurais Artificiais (RNA).

Utilizando conhecimento do estado da arte em detecção de movimentos no Skate, foram gerados 181 registros artificiais, resultando em 543 sinais de aceleração (X, Y e Z) divididos entre 5 classes de manobras. Foi desenvolvida uma heurística de classificação utilizando coeficientes de correlação cruzada para discriminar cada classe, e com a *Neural Network Toolbox* foi criada uma *Multilayer Feed Forward Network* de três camadas treinada através de um algoritmo de aprendizagem supervisionado (*scaled conjugate gradient backpropagation*).

Os resultados mostraram que com a utilização de RNAs treinadas especificamente para cada eixo, sendo o eixo Z o maior discriminador, podemos alcançar um percentual de erro inferior a 0.05%, com uma eficiência computacional que disponibiliza respostas em tempo real.

Aprendizado de máquina é uma poderosa ferramenta na classificação de padrões de movimento complexos, contanto que os classificadores sejam arquitetados de maneira eficiente e o problema proposto de maneira clara, essa técnica possui promissoras aplicações para Exergames e detecção de movimentos.

Palavras-chave: Skate, Acelerometria, Redes Neurais Artificiais, *Exergames*.



## ABSTRACT

Skateboarding is one of the most popular cultures in Brazil, with more than 8.5 million skateboarders. Today Skateboarding is more recognize as a true sports discipline, also given by its debut on the Olympic Games in Tokyo 2020.

The present study aims to develop methods detection and classification of Skateboarding flat ground tricks, using a Inertial Module Unit (IMU) allied whit Artificial Neural Networks (ANN). Using state of the art knowledge on movement detection in Skateboarding, 181 artificial flat ground tricks divided between 5 different classes were generated, equivalent to 543 signals (X, Y and Z) of acceleration. A classification heuristic based on cross-correlation coefficients was applied to the discriminate between classes, and using the Neural Network Toolbox a Multilayer Feed Forward Network was architect with three layers and a scaled conjugate gradient back propagation algorithm.

The results showed that with the use of ANNs trained specifically for each axis measured by the IMU, being the Z-axis the best differentiator, we can reach error percentages inferior to 0.05 %, with a computational efficiency that makes real time applications possible.

Machine learning is a useful tool in pattern recognition of complex movements, as long that the classifiers are properly architected and the task is expressed with clarity this technique is a promising application in Exergames and motion detection.

Keywords: Skateboarding, Accelerometry, Machine learning, Exergames.

## LISTAS DE ILUSTRAÇÕES

Figura 1 – Skate e seus componentes individuais.....	26
Figura 2 – Bases fundamentais do Skate, goofy (pé direito a frente) e regular (pé esquerdo a frente).....	27
Figura 3 – Posicionamento dos pés das possíveis variações de base de um skatista regular (Fakie, Nollie e Switch).....	28
Figura 4 – Movimento de remada de um skatista <i>regular</i> dividido em quatro etapas (a – d).....	29
Figura 5 – Diagrama da manobra Ollie dividida em seis etapas (a – f) .....	30
Figura 6 – Média de OAV durante a realização de uma série de AP RWS em alta velocidade, entre homens e mulheres skatistas.....	32
Figura 7 – FC e $VO_2$ estimado durante uma sessão de Skate com 30 minutos de duração.....	34
Figura 8 – Simulador de Skate, Top Skater da <i>Prime Time Amusements</i> .....	44
Figura 9 – <i>Tilt n' Roll, exertion game</i> para a prática do Skate.....	45
Figura 10 – Montagem do sistema de aquisição utilizando um elevador de PVC modificado.....	45
Figura 11 – Sistema de Eixos $x^a, y^a, z^a$ .....	47
Figura 12 – Deslocamento de um ponto representado pela soma do ponto $P(x_0, y_0)$ pelo vetor $\vec{v}$ .....	48
Figura 13 – Movimento de Translação (a) e Movimento de Rotação (b).....	48
Figura 14 – Translação do ponto $A$ para o ponto $B$ .....	49

Figura 15 – Ponto $p$ representado por dois referenciais diferentes, sistema de coordenadas $Q_p$ e $R_p$ .....	50
Figura 16 – Posição angular de uma reta de referência em relação ao eixo $x$ .....	51
Figura 17 – Deslocamento de 90 graus de um ponto no plano $x, y$ .....	52
Figura 18 – Representação geométrica da equação do movimento relativo.....	53
Figura 19 – Sistema massa–mola com sensor para medir aceleração com base na deformação da mola.....	55
Figura 20 – Ilustração de um acelerômetro MEMS.....	55
Figura 21 – Acelerômetro MEMS bi–axial na posição horizontal.....	56
Figura 22 – Giroscópio de diapasão, fabricado em silício cristalino pelo processo de dissolução da lâmina de silício.....	57
Figura 23 – Imagem de microscopia eletrônica de um giroscópio tipo anel ressonante suspenso por um campo eletromagnético.....	58
Figura 24 – IMU composta por acelerômetros e giroscópios que detectam aceleração linear e angulares múltiplos eixos.....	58
Figura 25 – Diagrama de orientação dos eixos da IMU acoplada ao skate.....	60
Figura 26 – Funções de transferência: Função de limiar (a), Função de limiar por partes (b), função sigmóide (c).....	65
Figura 27 – Representação matemática de um neurônio artificial (k).....	66
Figura 28 – Rede Neural Direta de Uma Camada.....	69
Figura 29 – Rede Neural Direta de Multicamadas.....	68
Figura 30 – Redes Neurais Recorrentes (Feed Backward).....	69

Figura 31 – Diagrama representando um algoritmo de aprendizado Não supervisionado (K-means).....	71
Figura 32 – Diagrama representando um algoritmo de aprendizado supervisionado, onde o sinal erro $\epsilon$ é retropropagado pela rede.....	72
Figura 33 – Diagrama dos componentes da placa de aquisição.....	75
Figura 34 – Esquema de alinhamento dos eixos do sensor inercial LSM6DS3H.....	76
Figura 35 – Relógio STEVAL–WESU1.....	77
Figura 36 – Sensor LSM6DS3 do Sistema STEVAL–WESU1.....	77
Figura 37 – Orientação dos eixos do sensor LSM6DS3.....	78
Figura 38 – Orientação da rotação do skate com base nos eixos do Z (a), X e Y (b).....	79
Figura 39 – Sinal de Base.....	80
Figura 40 – Modelagem do Sinal artificial.....	80
Figura 41 – Comparação entre o Nollie referência e o sinal artificial.....	81
Figura 42 – SHOV gerado artificialmente com ruído gaussiano acrescentado.....	81
Figura 43 – Assinatura das classes entre os eixos de aceleração X, Y, Z.....	82
Figura 44 – Correlação cruzada entre o FLIP 1 e o FLIP 2, eixo X.....	83
Figura 45 – Correlação cruzada entre todos os sinais do eixo X de FLIP.....	84
Figura 46 – Arquitetura da Rede Neural Artificial.....	85
Figura 47 – Performance da RNA XYZ e RNA Z, Performance (Entropia-Cruzada) x número de iterações (épocas).....	91
Figura 48 – Receiver Operating Characteristic do treinamento e validação da RNA XYZ.....	93

Figura 49 – Receiver Operating Characteristic na classificação dos sinais do eixo-Z.....	94
Figura 50 – Receiver Operating Characteristic da RNA X classificando os sinais do eixo-Y.....	95
Figura 51 – Arquitetura do classificador formado por RNAs especializadas.....	99
Figura 52 – Modelo tridimensional do suporte renderizado pelo SolidWorks 2016.....	101
Figura 53 – Montagem do suporte em MDF.....	102
Figura 54 – Montagem do suporte/sistema de aquisição no shape.....	102

**LISTA DE SIGLAS**

CBSk – Confederação Brasileira de Skate  
CDG – Centro de Gravidade  
IBOPE – Instituto Brasileiro de Opinião Pública e Estatística  
COI – Comitê Olímpico Internacional  
TSC – Tokyo Skateboarding Commission  
FIRS – *Fédération Internationale de Roller Sports*  
ISF – *Internationale Skateboarding Federation*  
RWS – *Rhythmic Weight Shift*  
OAV – *On Axis Velocity*  
APA – Ajustes Posturais Antecipatórios  
CR – Conhecimento do Resultado  
FC – Frequência Cardíaca  
VO<sub>2</sub> – Consumo de Oxigênio  
VO<sub>2max</sub> – Consumo de Oxigênio Máximo  
ACSM – *American College of Sports Medicine*  
UNESCO – Organização das Nações Unidas para Educação Ciência e Cultura  
SNC – Sistema Nervoso Central  
CAA – *Computer Assisted Assessment*  
IMU – *Inertial Module Unit*  
PVC – Policloreto de Vinila  
TPTSR – *The Pro Trainer Skateboarder Rehabilitator*  
USA – *United States of America*  
USD\$ – *United State Dollar*  
INPI – Instituto Nacional de Propriedade Industrial  
MEMS – *Micro Electro Mechanical System*  
I<sub>2</sub>C – *Inter Intergrated Circuit*  
SPI – *Serial Peripheral Interface*  
SAE – Society of Automotive Engineers – EUA  
USART – *Universal Synchronous Asynchronous Receiver Transmitter*

LSB – *Least Significant Bit*  
RMS – *root mean square*  
LIPO – *polymer lithium-ion battery*  
FSR – *force-sensing resistor*  
LDA – *Linear Discriminant Analysis*  
ECST – *Embedded Classification Software Toolbox*  
NV – *Naive Bayes*  
PART – *Partial Decision Tree*  
SVM – *Support Vector Machine*  
kNN – *k-nearest neighbor*  
RNA – *Rede Neural Artificial*  
MSE – *Mean Square Error*  
SCG – *Scaled Conjugate Gradient Backpropagation*  
Rprop – *Resilient Backpropagation*  
BFGS – *Algoritmo de Broyden-Fletcher-Goldfarb-Shanno*  
iNEMO – *inertial module*  
USB – *Universal Serial Bus*  
USCI – *Universal Serial Communication Interface*  
DMA – *Direct memory access*  
OLLIE – *alvo/classe correspondente a manobra Ollie*  
NSHOV – *alvo/classe correspondente a manobra Nollie Backside Shove it*  
SHOV – *alvo/classe correspondente a manobra Shov it*  
FLIP – *alvo/classe correspondente a manobra Kickflip*  
NOLLIE – *alvo/classe correspondente a manobra Nollie*  
RNA XYZ – *rede neural artificial treinada com todos os sinais (X, Y, Z)*  
RNA X – *rede neural artificial treinada com apenas os sinais do eixo X*  
RNA Y – *rede neural artificial treinada com apenas os sinais do eixo Y*  
RNA Z – *rede neural artificial treinada com apenas os sinais do eixo Z*  
ROC – *Receiver Operating Characteristic*  
MDF – *Medium Density Fiberboard*  
AI – *Artificial Intelligence*  
CIRL - *Cooperative inverse reinforcement learning*

## LISTAS DE SÍMBOLOS

A – ampere

a – aceleração

F – força

m – massa

$m/s^2$  – metros por segundo ao quadrado

$^\circ/s$  – grau/segundo

Kg – quilograma

cm – centímetro

% – porcentagem

min – minuto

ml – mililitro

kcal – quilocaloria

g – constante gravitacional terrestre

mg – milig (g/1000)

$x^a, y^a, z^a$  – Sistema referencial tridimensional

$\theta$  – ângulo

$\rightarrow$  – vetor

$v$  – velocidade instantânea

$v_{méd}$  – velocidade média

$a$  – aceleração instantânea

$a_{méd}$  – aceleração média

$\omega$  – velocidade angular média

$\ddot{r}_{B/A}$  – aceleração do ponto B em relação ao referencial

móvel

$\ddot{r}_A$  – aceleração de A em relação ao referencial fixo

$C_b^i$  – matriz de transformação do referencial móvel para um referencial fixo

$\dot{\omega} C_{ib}^b$  – vetor de aceleração angular no referencial móvel

$L^b$  – força específica do referencial móvel

$\Omega_{ib}^b$  – matriz antissimétrica correspondente ao vetor de velocidade angular

$\omega_{ib}^b$  – vetor de velocidade angular

$k$  – constante elástica da mola



$x, y, z$  – eixos referenciais do Simulador mecânico  
 $X, Y, Z$  – eixos referenciais do sensor LSM6DS3  
 AD – analógico/digital  
 $^{\circ}\text{C}$  – graus celsius  
 amostras/s – taxa de amostragem  
 $\varphi(\cdot)$  – função de transferência  
 $x_j$  – Sinal de entrada do neurônio  
 $W_{kj}$  – Pesos sinápticos das iterações  
 $\theta_k$  – bias  
 $\Sigma$  – combinador linear do neurônio  
 $y_k$  – Sinal de saída do neurônio  
 $N$  – número de padrões  
 $y_{d j}$  – valor de saída desejado  
 $N_e$  – número de neurônios nas camadas ocultas  
 $\varepsilon_{train}$  – tolerância  
 $N_{in}$  – número de neurônios na camada de entrada  
 $N_{out}$  – número de neurônios na camada de saída  
 Mpa – megapascal ( $10^6$ )  
 $\sigma_x$  – tensão de *Von Mises*  
 $\sigma$  – fator de segurança  
 kN – quilo newton ( $10^3$ )  
 $M$  – momento flexor máximo  
 $c$  – centro de gravidade  
 $I$  – momento de inércia  
 $S_y$  – resistência mínima de escoamento  
 mm – milímetros  
 V – volts  
 mA – miliampere  
 $\mu\text{A}$  – microampere  
 amostras/s – número de amostras coletadas em um segundo  
 mW – miliwatt  
 dBm – decibel miliwatt  
 Mbps – megabits/segundos  
 $X_{corr}$  – Correlação Cruzada

$\sigma_{Crr}$  - pico máximo da correlação cruzada

$xy\sigma_{Crr}$  – pico máximo da correlação cruzada de dois sinais x e y

## LISTAS DE TABELAS

Tabela 1 – Comparação entre tipos de RNA.....	69
Tabela 2 – Glossário de classes e suas respectivas movimentação.....	78
Tabela 3 – Alvos.....	82
Tabela 4 – Média de correlação para o Alvo OLLIE.....	87
Tabela 5 – Média de correlação para o Alvo FLIP.....	87
Tabela 6 – Média de correlação para o Alvo NSHOV.....	87
Tabela 7 – Média de correlação para o Alvo SHO V.....	88
Tabela 8 – Alvo OLLIE, comparação entre o método de AutoSoma e AutoCorrelação.....	89
Tabela 9 – Alvo FLIP, comparação entre o método de AutoSoma e AutoCorrelação.....	89
Tabela 10 – Alvo NSHOV, comparação entre o método de AutoSoma e AutoCorrelação.....	90
Tabela 11 – Alvo SHO V, comparação entre o método de AutoSoma e AutoCorrelação.....	90
Tabela 12 – Matriz de confusão dos coeficientes de correlação entre as cinco classes (eixo-Z).....	91
Tabela 13 – Matriz de confusão da RNA XYZ.....	92
Tabela 14 – Matriz de confusão da RNA Z.....	94
Tabela 15 – Matriz de confusão da RNA X classificando os sinais do eixo-Y.....	95
Tabela 16 – Matriz de confusão da RNA XYZ e suas classificações incorretas.....	96
Tabela 17 – Matriz de confusão do classificador Bayes Ingênuo.....	97
Tabela 18 – Performance dos Classificadores (Xcorr e RNA) .....	97

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>22</b>
1.1 OBJETIVO.....	25
1.2 OBJETIVOS ESPECÍFICOS.....	25
<b>2 FUNDAMENTOS TEÓRICOS .....</b>	<b>25</b>
2.1 FUNDAMENTOS DO SKATE .....	25
2.1.1 Skate – Dimensões e componentes.....	26
2.1.2 Bases.....	26
2.1.3 Posicionamento dos pés.....	28
2.1.4 Remada.....	28
2.1.5 Ollie.....	29
2.1.6 Física do Skate.....	31
2.1.7 Equilíbrio Postural em Skatistas.....	31
2.1.7.1 Controle do Centro de Gravidade.....	32
2.1.7.2 Implicâncias Posturais e Musculoesqueléticas do Skate.....	32
2.1.8 Respostas Metabólicas a prática do Skate.....	33
2.2 APRENDIZAGEM MOTORA.....	35
2.2.1 Aprendizagem Motora e Feedback.....	35
2.2.1.1 Feedback Intrínseco.....	37
2.2.1.2 Feedback Extrínseco.....	37
2.2.3 Capacidades Coordenativas.....	38
2.2.4 Coordenação Motora.....	38
2.2.5 Aspectos Relativos ao Equilíbrio Humano.....	39
2.3 ACIDENTES E LESÕES NO SKATE .....	40
2.4 SIMULAÇÕES E EXERGAMES.....	42
2.4.1 <i>Exertion Games</i> e o Skate.....	43
2.5 UNIDADES DE MEDIÇÃO INERCIAL ( <i>IMU</i> ).....	45
2.5.1 Sistema de Eixos.....	46
2.5.2 Vetores e Matrizes.....	46
2.5.3 Transformações Geométricas.....	47
2.5.3.1 Translação.....	48
2.5.3.2 Rotação.....	50
2.5.4 Equação de saída de um sensor inercial.....	52

2.5.5	Acelerômetros.....	54
2.5.6	Giroscópios.....	56
2.5.7	Utilização de IMU no Skate.....	59
2.6	<b>REDES NEURAIAS ARTIFICIAIS E CLASSIFICAÇÃO DE PADRÕES....</b>	<b>61</b>
2.6.1	O cérebro humano.....	62
2.6.2	Propriedades e Características de RNAs.....	64
2.6.3	Tipos de Redes Neurais Artificiais.....	66
2.6.3.1	Redes Diretas de uma Camada ( <i>Single–Layer Feed Forward Network</i> )..	67
2.6.3.2	Redes Diretas de Multicamadas ( <i>Multilayer Feed Forward Network</i> ).....	67
2.6.3.3	Redes Recorrentes ( <i>Feed–Backward</i> ).....	68
2.6.4	Treinamento de redes neurais: Não Supervisionado e Supervisionado..	70
2.6.5	Algoritmo de Retropropagação ( <i>Backpropagation</i> ).....	73
	<b>3 MATERIAIS E MÉTODOS .....</b>	<b>74</b>
3.1	SISTEMA DE AQUISIÇÃO.....	74
3.2	AMOSTRAS.....	78
3.3	GERAÇÃO DOS SINAIS E JANELAMENTO.....	79
3.4	HEURÍSTICA DE CLSSIFICAÇÃO.....	82
3.5	ARQUITETURA DA RNA.....	85
	<b>4 RESULTADOS E DISCUSSÃO.....</b>	<b>86</b>
4.1	RANKING DE RELEVÂNCIA DOS EIXOS X, Y, Z ENTRE OS ALVOS.....	86
4.2	CLASSIFICAÇÃO POR XCORR E COEFICIENTES DE CORRELAÇÃO... ..	88
4.3	CLASSIFICAÇÃO POR RNA.....	91
4.4	DISCUSSÃO E INTERPRETAÇÃO DOS RESULTADOS.....	96
4.5	APLICAÇÃO E PROPOSTA PARA FUTUROS ESTUDOS.....	100
	<b>5 CONCLUSÃO.....</b>	<b>103</b>
	<b>REFERÊNCIAS.....</b>	<b>105</b>
	<b>APÊNDICE A – DERIVAÇÃO MATEMÁTICA DO ALGORITMO DE</b>	
	<b>RETROPROPAGAÇÃO.....</b>	<b>118</b>
	<b>APÊNDICE B – Código (c) utilizado para geração do sinais</b>	
	<b>artificiais.....</b>	<b>122</b>

## 1. INTRODUÇÃO

A palavra skate é uma adaptação brasileira da palavra *skateboard*, que pode ser traduzida como “patins em uma prancha”. A tradução correta do termo *skateboard* remete as origens desse dispositivo, criado nos Estados Unidos durante a primeira metade do século 20 e provavelmente oriundo de outro engenho chamado de *roller scooters*, uma espécie de patinete com quatro rodas. O primeiro skate comercializado em massa foi o *Roller Derby* em 1959, feito com rodas de aço fora o veículo que popularizou o *sidewalk surfing* nos Estados Unidos. Durante toda década de 60, o skate foi totalmente influenciado pelo surf. Apenas em 1963, o termo *Skateboard* surgiu, criando uma identidade própria para a nova modalidade (CBSk, 2016).

Durante a década de 70 diversos eventos marcaram a história do Skate no mundo, tal como o desenvolvimento do Skate Vertical, um estilo moldado pela distinta arquitetura das piscinas californianas, na época em desuso devido a uma seca que assolou a Califórnia. Outros eventos importantes foram a invenção do *tail* inclinado, por Larry Stevenson, e a invenção da roda de poliuretano pelo engenheiro químico e surfista Frank Nasworthy em 1972, ambos feitos de engenharia que ajudaram a evoluir o Skate (CBSk, 2016).

A invenção da roda de poliuretano facilitou a prática do Skate e auxiliou a solidificá-lo como um esporte popular. Com esse crescimento no número de skatistas ocorre o surgimento da “cultura do skate”, mudando a visão do Skate sendo apenas uma variação do Surf.

A prática do Skate incorpora parte de uma categoria de esportes chamada *lifestyle sports*, tais como o Surf, Alpinismo, Paraquedismo, que tem como uma das características mais evidentes a busca por emoção, também denominada pela literatura como *sensation seeking* (SALOME, 2010). Porém diferente de outros *lifestyle sports* o skate foi um dos movimentos culturais mais influentes na história contemporânea da cultura jovem, tanto através da imagem, da estética, do comportamento, e demais aspectos que incorporam a cultura.

Christian Pociello (1995) afirma que o surgimento esportes como o Skate revolucionou em âmbito cultural a própria prática esportiva individual. A estetização e produção de novos gestos, dotados de estilo próprio, criaram um senso de individualismo em uma época aonde hegemonicamente havia a prevalência de esportes coletivos (BRANDÃO, 2008).

No Brasil o Skate teve seu começo na década de 60, e registros apontam que a atividade foi fomentada primeiramente no Rio de Janeiro, por filhos de norte-americanos e uma pequena parcela de brasileiros que tinham acesso à cultura dos EUA, mais especificamente indivíduos que praticavam o Surf. Em suas primeiras

aparições pelas terras cariocas o Skate obteve o nome de “surfinho”, similar ao *sidewalk surfing* que era a nomenclatura utilizada na época nos EUA (CBSk, 2016).

O Skate no Brasil teve diversos momentos, tantos de popularidade quanto exclusão, chegando até a ser proibido como prática esportiva duas vezes na cidade de São Paulo. A primeira, em 1975, devido aos graves acidentes causados pela sua prática, relacionados ao amadorismo do Skate no Brasil, e a segunda proibição, em 1988, devido à popularização da prática do esporte no Parque do Ibirapuera, algo que resultou em diversos conflitos levando à proibição da prática do Skate, ato que foi revogado apenas após a eleição da prefeita Luiz Erundina em 1989 (CBSk, 2016).

Mesmo assim o Skate nunca perdera o poder atrativo para com grande parcela da população, especialmente a jovem. Atualmente o skate é considerado um movimento cultural antigo o bastante para possuir sua própria história. O livro de Eduardo Britto “A Onda Dura” (2000), e o documentário brasileiro de longa-metragem “Vida Sobre Rodas” (2011) de Daniel Baccaro documentam as origens e os marcos históricos do skate no Brasil e no mundo, mostrando o ponto de vista de indivíduos que formaram a indústria e a cultura do skate em nosso país.

A popularidade do Skate no Brasil teve um crescimento significativo durante a última década. Um estudo em 2009, realizado pelo Instituto Datafolha, teve como objetivo medir a popularidade do Skate nos lares brasileiros, como também obter o perfil dessa população. O estudo mostrou que 3,8 milhões de indivíduos praticavam o Skate em 2009. O mesmo estudo apontou um crescimento de 123,68% em 2015, agora com um público de 8,5 milhões de adeptos (CBSk, 2016).

Além do número de praticantes o estudo do Instituto Datafolha apresentou diversos aspectos que caracterizam a população skatista, 11% dos domicílios brasileiros possuem pelo menos um morador que pratica o Skate, e essa penetração é maior entre os residentes das regiões metropolitanas do Sul e Sudeste do país. Atualmente ocorre um significativo crescimento da penetração da classe C no Skate, fazendo com que o perfil da população esteja mais concentrado na classe C (48%) do que nas classes A/B (44%). A média de idade do skatista brasileiro é de 37 anos, tendo mais mulheres (52%) do que homens praticantes (48%). Outra importante característica é a que a maior parte deste público (65%) é economicamente ativa, tendo sua maior parcela como assalariados registrados (CBSk, 2016).

Em suma, tais características demonstram que o Skate no Brasil é formado por uma grande população, economicamente ativa, e com poder aquisitivo de classe A, B e C, algo que faz com que a indústria do Skate seja uma ramificação extremamente bem sucedida da economia brasileira.

Além de possuir uma grande e economicamente ativa população, o Skate possui aspectos que podem ser traduzidos para diversas outras culturas e esportes que envolvem o *sensation seeking*, tendo assim um atrativo para com um público muito mais abrangente do que apenas o skatista. Venda de roupas e acessórios movimenta um mercado de mais R\$ 1 bilhão ao ano, enquanto o setor calçadista movimenta ao ano R\$ 40 bilhões no Brasil segundo o Instituto Brasileiro de Opinião Pública e Estatística (IBOPE) (CBSk, 2016). Em 2014, na segunda edição da URB em São Paulo, mais de 5,000 lojistas de todo o país se reuniram, movimento que gerou mais de R\$ 100 milhões em vendas business-to-business (CBSk, 20116).

O Skate se divide em diversas modalidades, onde cada uma aborda terrenos diferentes, com técnicas e equipamentos distintos, entre essas modalidades podemos citar como exemplo o Vertical, o Bowl, o *Downhill*, o *Freestyle*, entretanto a modalidade mais praticada entre os skatistas tanto no Brasil quanto no mundo é o Street. Modalidade essa que surgiu nos Estados Unidos no final da década de 70, e atualmente engloba 95% de todos os praticantes de Skate no mundo (CBSk, 2016). O *Street* é uma modalidade do Skate que se baseia em utilizar a arquitetura urbana (bancos, muros, escadas, corrimões) como obstáculos. Para superar tais obstáculos, o skatista usa de um arsenal de diferentes tipos de manobras (REED, 2002).

Em 03 de agosto de 2016, um importante anúncio para o Skate mundial foi emitido pelo Comitê Olímpico Internacional (COI), onde o Skate se tornou um dos cinco esportes a estrear nos Jogos Olímpicos de Tóquio em 2020. A Tokyo 2020 Skateboarding Commission (TSC), uma parceria entre a *Fédération Internationale de Roller Sports* (FIRS) e a *International Skateboarding Federation* (ISF), juntamente com o COI, irão assegurar competições de Skate nos Jogos Olímpicos de Tóquio, onde uma das modalidades confirmadas é o Street (TSC, 2016).

Após o anúncio do COI a prática desportiva do Skate no Brasil pode ser equiparada a de esportes clássicos de nossa cultura. Contudo o Skate por muito tempo foi considerada uma atividade marginal, e por conta disso sempre houve uma escassez de material científico relacionado à sua prática.

Skatistas na atualidade possuem pouco acesso a treinamentos baseados em evidências científicas, pois o Skate raramente é trabalhado dentro de ambientes acadêmicos, onde inúmeras práticas da ciência encontram aperfeiçoamento. E diferente de práticas esportivas mais estudadas e que já possuem um forte embasamento na literatura, a produção científica encontrada sobre o Skate é escassa e superficial.

O Skate é uma prática esportiva adotada por milhões de crianças, onde a cada ano mais praticantes novatos iniciam a prática desta modalidade, contudo estudos



mostram que de todas as lesões relacionadas ao Skate, 52% dessas ocorrem em crianças com idade inferior a 15 anos, e 33% de todos os lesionados pela prática do Skate são praticantes iniciantes (AAOS, 2013) (FOUNTAIN; MEYERS, 1996). Parece que no Skate, os mais fragilizados pela idade e desenvolvimento motor são os mais suscetíveis a acidentes e lesões, tendo em vista esta realidade contramedidas para remediar o número de lesões no esporte devem ser almejadas (MCKENZIE et al, 2016). *Exertion Games*, jogos onde é requisitado o investimento de ação física por parte do usuário (MÜLLER et al, 2008), podem auxiliar no desenvolvimento de novos métodos para a aprendizagem e aprimoramento de técnicas de Skate, algo já explorado em outros esportes e atividades que envolvam movimentações corporais (STIENSTRA et al, 2011) (BORKER; CRAWLEY, 2001) (MARC et al, 2009).

Com a ascensão do Skate a status de esporte popular e Olímpico, juntamente com a falta de conhecimento científico e risco envolvendo a prática do Skate em seus estágios iniciais, faz-se necessária a busca pelo entendimento dos elementos que fundamentam a prática esportiva dessa modalidade, utilizando-se do método científico para ampliar e melhorar nossa compreensão de um dos esportes mais populares no Brasil e no mundo.

## **1.1 OBJETIVOS**

O presente estudo tem como objetivo principal instrumentar ferramentas que auxiliem na aprendizagem de técnicas de *Street Skate*, utilizando acelerometria e *Machine Learning* para aprimorar o desenvolvimento desse esporte.

## **1.2 OBJETIVOS ESPECÍFICOS**

- Desenvolver um sistema de aquisição para medição das acelerações impostas sobre o skate/simulador;
- Desenvolver um método eficiente de classificação de manobras.

## **2. FUNDAMENTOS TEÓRICOS**


### **2.1 FUNDAMENTOS DO SKATE**

O Skate como atividade física possui uma série de fundamentos que incorporam as técnicas básicas de deslocamento, apenas quando o praticante adquire equilíbrio, postura e segurança para se deslocar independente da direção do skate, é que a aprendizagem de técnicas mais avançadas pode ser almejada. Tais fundamentos, como também as exigências fisiológicas, maneira como ocorre à aprendizagem, e a física por trás do movimento do skate/skatista serão revisados nessa seção.

### 2.1.1 Skate – Dimensões e componentes

Um skate consiste de uma tábua chamada de shape, o nose e o tail ambos são extremidades do shape, sendo o nose a parte dianteira e o tail a traseira. O shape é fixado por oito parafusos de base a dois eixos que garantem a mobilidade e controle do skate. Por fim, os eixos são ligados a quatro rodas onde todas as rodas possuem dois rolamentos esféricos em seu interior. Na Figura 1 é ilustrado um skate dividido em seus componentes. O número de modelos de skate disponível na atualidade é vasto, no entanto, ilustramos um tamanho padrão de skate moderno, com uma média de 83 cm de comprimento, 26 cm de largura e 16 cm de altura, pesando aproximadamente 2,3 Kg.

Figura 1 – Skate e seus componentes individuais.



Fonte: O autor (2017).

### 2.1.2 Bases

Base é o nome dado as diferentes maneiras nas quais os pés do praticante podem ser posicionados sobre o skate, seja para o deslocamento ou para a preparação de alguma manobra mais complexa. Existem quatro bases possíveis, regular, goofy, nollie e fakie.

Durante a iniciação a prática do Skate é necessário que o indivíduo defina alguma lateralidade preferencial, ou seja, qual lado do corpo (esquerdo ou direito) será posicionado a sua frente, dado pelo fato que o corpo do skatista deve estar próximo de um ângulo perpendicular em relação ao seu deslocamento. Esta lateralidade é que dá origem as duas bases fundamentais, regular e goofy (GROH et al, 2015) (SANTOS, 2008).

A escolha da base nem sempre é relacionada com outras lateralidades corporais, como por exemplo, a lateralidade manual (destro/canhoto). Essa lateralidade definida, ou base, é refletida na postura e na distribuição do centro de gravidade (CDG) do indivíduo entre o plano anterior e posterior do skate, pé esquerdo e pé direito. Indivíduos que preferenciam o pé esquerdo no plano anterior do skate, com o corpo voltado para o sentido horário e o ombro esquerdo apontando para frente, são chamados de regulares, e indivíduos que optam pela base contrária são os goofys, como é demonstrado na Figura 2 (GROH et al, 2015).

Figura 2 – Bases fundamentais do Skate, goofy (pé direito a frente) e regular (pé esquerdo a frente).



Fonte: O autor (2017).

Na prática do Skate, a alternância da base ou switch como também é conhecida, ocorre quando regulares manobram como goofys ou vice-versa. Para melhor entendimento da alternância de lateralidade, podemos usar a analogia de um tenista que escolhesse trocar a mão que costumeiramente segura sua raquete. Isso é algo que praticantes mais experientes optam no Skate pelo desafio e dificuldade que tal alternância causa, e também pela ampliação do repertório de manobras quando as executamos em ambas as bases (SILVA; BERTUZZI, 2004).

As outras duas bases, nollie e fakie, não alteram a lateralidade original do praticante, contudo a nollie exige com que o skatista posicione seus pés mais a frente do skate, enquanto a fakie é a mesma postura original do indivíduo onde o que muda nessa situação é a direção do deslocamento (GROH et al, 2015).

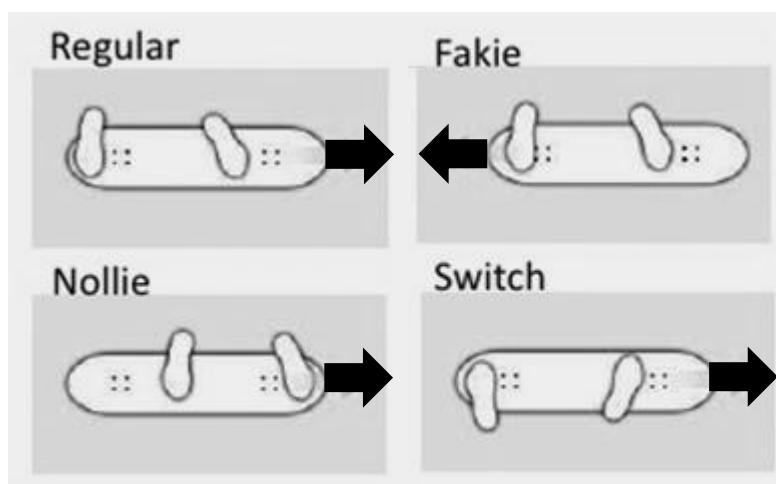
### 2.1.3 Posicionamento dos pés

Para o correto posicionamento dos pés, o corpo do skatista deve se encontrar perpendicular em relação à direção do seu deslocamento, com o ombro

correspondente do pé anterior apontando para frente, e o ombro correspondente ao pé posterior apontando para trás. Quanto mais perpendiculares estiverem os pés, melhor será para controlar a intensidade das curvas do skate, deslocando o CDG tanto para frente, inclinando-se na direção da ponta dos pés, quanto para trás, inclinando-se na direção dos calcanhares. O pé de trás não deve ultrapassar a parte posterior do skate (tail) enquanto o pé da frente se posiciona sobre ou atrás do eixo anterior, sendo utilizados os parafusos de base do eixo como referência (SANTOS, 2008).

Na Figura 3 podemos observar o exemplo do posicionamento dos pés de um skatista *regular* nas quatro bases fundamentais do Skate, como também a direção do seu deslocamento simbolizada por setas.

Figura 3 – Posicionamento dos pés das possíveis variações de base de um skatista regular (Fakie, Nollie e Switch).



Fonte: O autor (2017).


#### 2.1.4 Remada

Após a determinação da base para movimentarmos o skate em uma superfície plana, é necessário embalá-lo com um dos pés, movimento também conhecido como “remada”. A correta técnica de remada preza que o indivíduo mantenha o pé dianteiro firme sobre o skate, esse agindo como base durante o movimento, enquanto o pé posterior impulsiona o solo com um movimento similar a de uma passada, diferentes grupamentos musculares são ativados em sincronia para que a embalada seja executada de maneira harmoniosa (AMBRUST, 2010; DETERMAN et al, 2010).

O correto posicionamento do pé anterior é importante, pois atua como base durante todo o movimento de remada. Esse deve ser situado atrás ou sobre os parafusos do eixo anterior em diagonal, no sentido medial em relação ao corpo do skatista (SANTOS, 2008). Na Figura 4 observamos o movimento de remada dividido em quatro etapas, na primeira etapa o praticante encontrasse com o pé anterior posicionado sobre o skate e o pé posterior ao lado do skate sobre o solo (a), na

segunda etapa o praticante estende o quadril e o joelho para trás enquanto se apoia sobre o pé anterior (b), gerando assim um deslocamento para frente (c), e na última etapa o praticante assume sua base sobre o skate, (d) no caso do exemplo, *regular*.

Figura 4 – Movimento de remada de um skatista *regular* dividido em quatro etapas.



Fonte: O autor (2017).


### 2.1.5 Ollie

Uma das técnicas mais básicas no Skate é o Ollie, inventado na Flórida no final de 1970 por Alan Ollie Gelfand (SANTOS, 2008 apud REED, 2002). Essa técnica deu origem a diversas outras mais complexas, principalmente no Street Skate. O Ollie é análogo ao ato de pular (TESLER, 2000), sendo que consiste basicamente de um salto, onde ambos o skatista e o skate são elevados em um movimento contínuo e harmonioso. Assim esse movimento permite que o skatista consiga transpor obstáculos, subir, descer ou montar em diferentes tipos de estruturas, algo que requer habilidade, precisão, força e potência (BRIDGMAN; COLLINS; COLLINS, 1992).

Na Figura 5 podemos ver um diagrama da manobra Ollie. No primeiro momento (a) o skatista encontrasse sobre o skate com o pé dianteiro posicionado atrás dos parafusos do eixo anterior, e o pé posterior sobre a ponta do tail, o corpo do skatista fica perpendicular em relação ao deslocamento, com ambos os joelhos flexionados. Para executar o Ollie o praticante rapidamente pressiona a ponta do tail do skate fazendo com que ele rote no eixo do truck traseiro, elevando o pé dianteiro

conforme a frente do skate se eleva (b e c). O golpe do tail contra o solo faz com que o skate seja impulsionado para cima, conforme o skate se eleva o skatista também salta utilizando o pé dianteiro para empurrar o *nose* do skate para frente, enquanto ao mesmo tempo encolhe o pé traseiro, assim assumindo a postura para controlar a orientação espacial do skate pelo salto (d). Se executado corretamente o skatista e o skate seguem trajetórias similares, e o skatista aterrissa sobre o skate flexionando os membros inferiores para absorver o impacto (e e f) (FREDERICK et al, 2006) (BRIDGMAN e COLLINS, 1992).

Figura 5 – Diagrama da manobra Ollie dividida em seis etapas (a – f).



Fonte: (FREDERICK, E. C. et al. 2006).

O salto como fundamento é algo comum em muitos esportes. Em algumas modalidades essa capacidade representa um fator chave para a alta performance, inclusive no Skate, onde ao saltar verticalmente ou horizontalmente está totalmente relacionada com a altura e a distância do Ollie (CADOTTI et al, 2012). Porém no Skate as técnicas de salto são executadas e influenciadas não apenas pelas capacidades físicas do indivíduo, mas também por fatores extrínsecos relacionados com o próprio skate, tais como o peso e tamanho do shape, tamanho e inclinação do tail ou nose, altura e tamanho das rodas e o tipo de superfície (solo) (CADOTTI et al, 2012).

Diversos estudos são realizados para que os fatores determinantes para a performance do salto sejam esclarecidos, tamanha a importância deste gesto motor para certas modalidades (HASSON et al, 2004). Contudo, no skate a contribuição dos fatores intrínsecos e extrínsecos para a execução do Ollie ainda são ignotos, assume-se que a força muscular e potência de membros inferiores sejam elementos determinísticos para o desempenho desta técnica (NAGANO et al, 2005).

#### 2.1.6 Física do Skate

Manobras de skate podem ser interpretadas como a aplicação de uma força com um sentido/direção específica, com o intuito de fazer com que o skate realize algum movimento distinto. No *Street* skatistas realizam manobras que envolvem saltar com o skate combinando o salto com a rotação do skate e/ou do corpo do praticante

em diferentes eixos de direção. Manobras complexas envolvem a rotação do skate em até três eixos simultâneos, podendo também haver a rotação do corpo do skatista no eixo longitudinal (REED, 2002).

Contudo, por mais complexas que manobras de skate pareçam, todas podem ser descritas pelas três Leis de Newton. Em 1687 Isaac Newton publicou suas três leis no seu *Philosophiae Naturalis Principia Mathematica* (Princípios Matemáticos da Filosofia Natural) onde observações feitas por pesquisadores do passado, como Galileo Galilei e Johannes Kepler, foram extendidas e descritas através de uma nova linguagem matemática, o cálculo (HALLIDAY et al, 2010 apud NEWTON, 1729).

As três Leis de Newton podem ser resumidas utilizando o exemplo da remada do Skate. Ambos o skate e o skatista constituem uma massa total que corresponde à medida de inércia de ambos, isto é, a resistência que o corpo tem para variar sua velocidade. Enquanto a força resultante no skate e no skatista for nula, ambos permaneceram em repouso (1ª Lei de Newton). Quando o skatista aplica uma força  $\vec{F}$  contra o solo,  $\vec{F}$  sendo  $= m\vec{a}$ , a força executada pela remada do conjunto skate/skatista é igual ao produto da variação de velocidade (aceleração) pela massa do corpo em questão (2ª Lei de Newton). Contudo o skatista só obtém uma variação positiva em sua velocidade por que o solo reage com uma força igual e em sentido contrário a remada do skatista, o impulsionando para frente (3ª Lei de Newton).

Em tarefas mais complexas, como por exemplo na execução da manobra Ollie, o fato de que a força  $\vec{F}$  imposta pelo skatista sobre o skate pode ser interpretada (e medida) como uma aceleração  $\vec{a}$ , nos permitira diferenciar manobras através da orientação espacial deste vetor.

## 2.1.7 Equilíbrio Postural em Skatistas

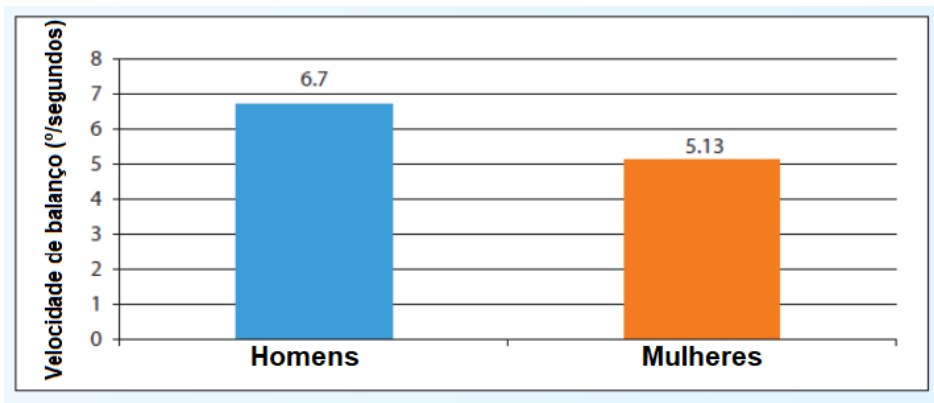
O equilíbrio representa uma das mais importantes capacidades físicas para o praticante do Skate, onde o contínuo ajuste do CDG é necessário para que a correta postura seja mantida ao se manobrar o skate, contudo é necessária uma boa postura para que o controle do CDG do indivíduo seja facilitado. Assim um bom controle da postura reflete em uma melhora no equilíbrio, mas outros fatores influenciam e serão discutidos nesta seção.

### 2.1.7.1 Controle do Centro de Gravidade

Tovar e colaboradores (2014) realizaram um estudo com o propósito de examinar os efeitos do gênero na habilidade de mover ritmicamente o CDG, onde dezoito indivíduos (10 controles e 8 skatistas) realizarão uma série de AP (ântero-posterior) *Rhythmic Weight Shift* (RWS) testes em um *NeruoCom Smart Balance*

*Master*. Não houve variações na velocidade do grupo controle, porém ocorreu uma variação no grupo formado por praticantes de Skate. A média da OAV (*On Axis Velocity*) foi significativamente maior em indivíduos do sexo masculino (OAV  $6,7 \pm 54$  %/s) do que do sexo feminino (OAV  $5,13 \pm 1,18$  %/s) (Figura 6) em testes de alta velocidade, nos testes envolvendo velocidades lentas e medianas de RWS não houve diferenças significativas (TOVAR et al, 2014).

Figura 6 – Média de OAV durante a realização de uma série de AP RWS em alta velocidade, entre homens e mulheres skatistas.



Fonte: TOVAR et al, (2014).

Os resultados sugerem que a prática do Skate produz uma variação significativa no controle do CDG no plano ântero–posterior entre homens e mulheres, um dos possíveis motivos apontado seria atribuído a o fato de homens possuírem mais força nos membros inferiores, ocasionando em uma maior velocidade no ajuste do CDG (TOVAR et al, 2014).

#### 2.1.7.2 Implicâncias Posturais e Musculoesqueléticas do Skate

Pelo fato de durante a iniciação o Skate ser normalmente trabalhado de maneira unilateral, no que diz respeito à base e a remada, regular/goofy, skatistas tendem a exercitar de maneira desigual as musculaturas laterais do corpo, o que levaria a prática do Skate a causar dissimetrias posturais por gerar um fortalecimento assimétrico do corpo, algo comum em esportes que priorizam uma lateralidade definida em seus fundamentos, como o tênis e voleibol.

Contudo, um estudo realizado em 2014, com uma amostra composta por 10 skatistas de categoria amadora (categoria anterior a profissional), realizou quatro procedimentos de avaliação, incluindo (1) teste de força máxima isométrica, (2) teste de comprimento muscular, (3) medida das alturas dos ângulos inferiores das escápulas, espinha íliaca póstero–superior, linha poplítea do joelho e (4) questionário sobre a metodologia aplicada no esporte (SCHILING et al, 2014).



Esse estudo verificou que não existia uma diferença significativa entre tônus/força muscular, comprimento muscular e alturas corporais entre ambos os lados do corpo em praticantes de skate. Tais evidências apontam que independentemente da lateralidade ou base definida como preferencial na prática do Skate, um equilíbrio muscular e postural pode ser alcançado através da prática desta modalidade, fato esse que pode ser relacionado com a ampla variedade de movimentações possíveis no Skate. Isso contrabalancearia a pouca alternância na lateralidade da base de skatistas mais experientes. Contudo, os efeitos da prática do Skate na postura de praticantes iniciantes ainda é desconhecido (SCHILING et al, 2014)

Uma boa manutenção da postura durante a prática do Skate é essencial para seu bom desempenho. Cada manobra no Skate possui uma determinada postura a ser empregada antes, durante e após sua execução. No caso do Ollie, a postura que precede a manobra é fundamental para o seu bom desempenho, e ajustes nessa postura tem uma importante função (CESARI et al, 2014).

Comportamentos antecipatórios são uma resposta neuromuscular definida por ajustes posturais antecipatórios que ocorrem por todo o corpo do indivíduo anteriormente a uma determinada tomada de ação ou movimento (SHIRATORI; LATASH, 2001). Ajustes posturais podem ser detectados previamente a iniciação voluntária de qualquer movimento, causando ajustes no centro de gravidade do indivíduo conforme a demanda do gesto pretendido (MASSION, 1992).

Para que o skatista possa melhorar seu processo de aprendizagem e aprimorar seu repertório de manobras, é primeiro necessário que o indivíduo possa controlar habilmente seu CDG, enquanto mantendo a postura apropriada para a execução da manobra desejada. O equilíbrio realmente se mostra um aspecto crítico para o desenvolvimento da prática do Skate, especialmente em um esporte onde a causa mais comum de lesões é a queda por desequilíbrio (FORSMAN; ERIKSSON, 2001).

#### 2.1.8 Respostas Metabólicas a prática do Skate


Um estudo feito por Hetzler e colaboradores, (2001), teve o objetivo de examinar os efeitos que o Skate teria sobre o consumo de oxigênio ( $VO_2$ ) e a frequência cardíaca (FC), para estimar as demandas metabólicas da prática do Skate durante um teste de campo.

Foram utilizados 10 skatistas, grupo formado por oito homens e duas mulheres, que possuía as seguintes características: idade  $24,5 \pm 3,1$  anos, peso  $80,3 \pm 8,3$  Kg, altura  $176,2 \pm 6,6$  cm, %Gordura  $11,5 \pm 6,2\%$ ,  $VO_{2max}$   $53,2 \pm 5,2$  ml  $\cdot$  kg<sup>-1</sup>  $\cdot$  min<sup>-1</sup> (média  $\pm$  desvio padrão). O grupo participou de um teste de campo que consistia da prática contínua do Skate (Remada) por 30 minutos por uma superfície plana e lisa

(arena esportiva indoor) de concreto utilizando um monitor cardíaco para o monitoramento da FC (HETZLER et al, 2001).

Para estimativa do consumo máximo de oxigênio foi utilizada a média de FC entre 5 intervalos de um minuto. Esses intervalos de um minuto foram registrados ao longo de toda a avaliação. Assim, a média do  $VO_{2max}$  alcançada durante 30 minutos de Skate fora de  $28,6 \pm 2,3 \text{ ml}\cdot\text{kg}^{-1} \cdot \text{min}^{-1}$  como mostra a Figura 7 (HETZLER et al, 2001).

Figura 7 – FC e  $VO_2$  estimado durante uma sessão de Skate com 30 minutos de duração.



Fonte: (HETZLER et al, 2001)

O estudo mostrou que o Skate poderia ser utilizado como método alternativo de esporte para jovens adultos saudáveis (HETZLER et al, 2001), pois para aumentar a capacidade cardiorrespiratória o *American College of Sports Medicine* (ACSM) recomenda que exercícios físicos sejam praticados de 3 a 5 vezes ou dias/semana, por 20 – 60 minutos, em intensidades entre 40% e 85% da capacidade respiratória máxima ( $VO_{2max}$ ) (FRANKLIN, 2000).

A média e desvio padrão do  $VO_{2max}$  a intensidades de 50% (controle) do grupo amostral seria de  $28,6 \pm 2,6 \text{ ml}\cdot\text{kg}^{-1} \cdot \text{min}^{-1}$ , enquanto o valor obtido durante o teste de campo fora de  $28,6 \pm 2,3 \text{ ml}\cdot\text{kg}^{-1} \cdot \text{min}^{-1}$ , este valor pode estar na parte menos intensa do espectro, mas mesmo assim satisfaz as diretrizes de exigências da ACSM (HETZLER et al, 2001).

Quando convertidos os dados do consumo de oxigênio do teste de campo para a expedição calórica, a média e desvio padrão obtidos para a prática de 30 minutos de Skate foi de  $308,6 \pm 37,9$  kcal ao total, com valor respectivo de  $\text{kcal} \cdot \text{min}^{-1}$  de  $10,3 \pm 1,3$   $\text{kcal} \cdot \text{min}^{-1}$  (HETZLER et al, 2001). Esses dados são concordantes com valores encontrados em atividades similares, como o *in-line* (roller) ( $9,5 \text{ kcal} \cdot \text{min}^{-1}$ ), basquete ( $10,9 \text{ kcal} \cdot \text{min}^{-1}$ ), canoagem ( $9,5 \text{ kcal} \cdot \text{min}^{-1}$ ), dança aeróbica ( $10,0 \text{ kcal} \cdot \text{min}^{-1}$ ), voleibol ( $10,7 \text{ kcal} \cdot \text{min}^{-1}$ ), escalada ( $10,8 \text{ kcal} \cdot \text{min}^{-1}$ ) e corrida ( $10,0 \text{ kcal} \cdot \text{min}^{-1}$ ), valores estimados para um peso médio de 75 kg (WILIAMS, 1999).

A ACSM recomenda que pessoas devam participar em atividades físicas o suficiente para que uma expedição calórica entre 150 kcal e 400 kcal por dia seja alcançada (FRANKLIN, 2000). Portanto o Skate, que com apenas 30 minutos de prática moderada em uma superfície plana gera uma expedição calórica de  $308,6 \pm 37,9$  kcal (HETZLER et al, 2001), acata as exigências da ACSM para prática de hábitos saudáveis.

Os autores do estudo reconheceram aquele como sendo a primeira pesquisa a examinar as respostas metabólicas do corpo humano a prática do Skate. Como principais achados do estudo foram considerados em primeiro que, a prática do Skate parece ser uma opção viável para desenvolver e manter a capacidade aeróbica, e em segundo que a prática de 30 minutos de Skate aparenta satisfazer as exigências diárias de expedição calórica em atividade física do ACSM, contudo para resultados mais conclusivos são necessários mais estudos na área de fisiologia do Skate (FRANKLIN, 2000) (HETZLER et al, 2001).

## 2.2 APRENDIZAGEM MOTORA

Nesta sessão revisaremos aspectos relacionados à aprendizagem motora em seus diferentes níveis de especialização, a importância das capacidades coordenativas, e quais são mais trabalhadas no Skate.

### 2.2.1 Aprendizagem Motora e Feedback

Podemos definir a aprendizagem como a mudança na capacidade de um indivíduo executar uma tarefa, tal mudança é intimamente relacionada com a prática e a experiência (familiarização com o movimento/tarefa), o que infere uma melhoria relativamente permanente no desempenho (MAGIL, 1989).

Estudiosos do comportamento motor identificam estágios no processo de aprendizagem motora de qualquer habilidade. O processo de aprendizagem pode ser descrito nas seguintes etapas; inexperiente (novato), intermediário e avançado (expert), (PELLEGRINI, 2000).

Durante o primeiro estágio, o novato ainda não possui um modelo mental claro de como executar a tarefa, assim a descoordenação dos movimentos, movimentações desnecessárias e falta de fluência na movimentação, são consequências de um sistema cujas respostas motoras estão tentando encontrar a melhor solução para executar a tarefa. No estágio intermediário ocorre um polimento do gesto motor, eliminando-se movimentos desnecessários e com isso economizando tempo e energia, tornando assim a sequência de execuções mais harmônica e com uma tendência maior ao acerto. No estágio avançado, ou expert, o indivíduo já possui todo um plano mental para como executar a ação com o mínimo de gasto energético, e com a maior velocidade e eficiência possível, algo que torna o movimento esteticamente elegante e harmonioso. A evolução pela busca da automatização de qualquer gesto motor tende a trilhar tais estágios de aprendizagem (PELLEGRINI, 2000)(UNESCO, 2013).

Pelo Skate ser uma prática esportiva individual onde não existem regras nem restrições, e muitas vezes sem a presença de um orientador, grande parte dos praticantes do Skate se tornam autodidatas tendo que criar seus próprios métodos, evoluções pedagógicas, metas e objetivos para a aprendizagem de movimentos extremamente técnicos e precisos. Skatistas possuem uma grande capacidade em aprendizagem motora, transferência de aprendizagem, concentração e capacidade de observação como também a habilidade de interpretar resultados positivos e negativos para a melhora de suas técnicas.

Em seu estudo Santos (2008) menciona que praticantes do Skate tendem a se organizar e vivenciar sua prática em grupos onde um tende a auxiliar o outro através de demonstrações visuais, explicações verbais, e também pela motivação.

Na busca por aprender novas técnicas praticantes do Skate, utilizam o feedback como um recurso durante o processo de aprendizagem. O feedback seria o conhecimento do resultado em relação ao objetivo da tarefa (SCHMIDT, 1992). Usa-se muito na literatura o termo conhecimento de resultado (CR), o que significa que o indivíduo está recebendo feedback.

Consideramos nesta revisão duas formas feedback, uma sendo fornecida de maneira externa sendo este denominado de feedback extrínseco, e a outra sendo a percepção do próprio praticante, denominada feedback intrínseco (SCHMIDT, 1992).

### 2.2.1.1 Feedback Intrínseco

Quando um indivíduo aprende alguma habilidade motora por tentativa e erro denominamos essa atividade como uma prática livre. Isso é o que chamamos de feedback intrínseco, ou seja, a aprendizagem proveniente do próprio indivíduo e de sua percepção do ambiente com o qual está interagindo (PIEKARZIEVCZ, 2004). Ocorre espontaneamente na execução de movimentos, sendo presente durante e após o desempenho da tarefa motora (MAGIL, 2000). Santos, (2008), descreve que esta capacidade de interpretar diferentes tipos de variáveis, como a posição dos pés, a velocidade do skate, o posicionamento do corpo após cada tentativa, e gerar uma mudança na execução do movimento é uma importante característica no processo de aprendizagem desses indivíduos.

Com esse método, o indivíduo, através da tentativa e erro, aprende quais os melhores métodos, e quais estratégias proporcionam uma melhora na execução da habilidade motora (GOODAMN et al, 2004). Dessa maneira, com a prática o skatista é capaz de desenvolver estratégias e técnicas mais refinadas de aprendizagem (LIAO; MASTER, 2001).

Contudo, durante a iniciação de qualquer habilidade motora, o praticante ainda está criando um padrão de movimento, que nem sempre é o mais eficiente, tornando assim as informações obtidas através da introspecção insuficientes, pois muitas vezes o praticante não é capaz de compreender a origem dos erros sendo cometidos (PROENÇA, 1988).

Apenas o feedback intrínseco não é suficiente para que o sujeito atinja um bom desempenho em sua habilidade motora, pois é fundamental que informações extrínsecas complementem a interpretação intrínseca do indivíduo (SWINNEN, 1996).

### 2.2.1.2 Feedback Extrínseco

O feedback extrínseco diz respeito as informações assimiladas sobre alguma tarefa, informações essas provenientes do meio externo e captadas pelos sistemas sensoriais do indivíduo, como os sistemas visual e proprioceptivo (MAGIL, 1991). A função deste tipo de feedback durante o desenvolvimento de qualquer habilidade motora é facilitar a aprendizagem (GOODMAN; WOOD; HENDRICKX, 2004)

Algo valioso neste tipo de CR, e que ele promove ajustes e correções na construção do gesto e da habilidade motora, ocasionando numa diminuição no número de tentativas malsucedidas (AYERS et al, 2003), algo que influencia positivamente diminuindo a incidência de lesões causadas pela falha na execução de alguma manobra. Esse pode ser considerado um dos principais aspectos do feedback

extrínseco, pois causa modificações em gestos motores incorretos, também denominados vícios motores (SANTOS, 2008).

Quando o aprendiz tem apenas uma resposta de que sua ação foi correta ou errada, dizemos que determinado CR é qualitativo ou que a informação está incompleta, enquanto o feedback extrínseco é considerado um tipo de informação quantitativa, pois possui informações relacionadas à magnitude do erro e a aspectos específicos da habilidade motora, como postura, posicionamento, controle do CDG entre outras (SCHIMIDT, 1992).

Feedback extrínseco pode inclusive auxiliar na formação de ações antecipatórias, também denominadas pela literatura de Ajustes posturais antecipatórios (APAs). Modelos teóricos indicam que nosso sistema motor atua de uma maneira antecipatória, e que ações são previamente estruturadas em um modelo interno antes de serem externadas (CUSUMANO; CESARI, 2006) (TODOROV; JORDAN, 2002). Estudos na área de ressonância magnética funcional (RMf) inclusive suportam a existência de uma simulação interna de gestos motores, causada pelo som que estes produzem (CESARI et al, 2014 apud D'AUSILIO et al, 2009, PULVERMÜLLER et al, 2006, WISLON, 2004). Tais evidências indicam a existência de um sistema espelho de neurônios entre a execução de uma ação motora e a percepção auditiva do som gerado por tal ação (KOHLENER et al, 2002), contudo o nível de familiaridade com a experiência motora influencia o quanto a presença de estímulos externos podem gerar uma ativação motora antecipatória significativa (CALVO-MERINO et al, 2006)(CESARI et al, 2014).

Isso demonstra o nível de influência dos estímulos externos e como o feedback extrínseco é uma ferramenta fundamental durante o desenvolvimento de habilidades motoras.

### 2.2.3 Capacidades Coordenativas.

Podemos classificar as Capacidades Motoras de um indivíduo em duas categorias, Capacidades Condicionais e Capacidades Coordenativas. As capacidades condicionais são aquelas que englobam características de cunho quantitativo, como a força e a resistência muscular, enquanto as capacidades coordenativas são as responsáveis por reunir as competências motoras de âmbito qualitativo, como o ritmo, a cinestesia, o equilíbrio e coordenação (GROSSER, 1983).

### 2.2.4 Coordenação Motora

De um ponto de vista fisiológico a coordenação motora é responsável por tornar a ação motora o mais econômica possível, tanto na economia energética quanto

na economia de gestos desnecessários, algo que invariavelmente agrega no gasto energético. A palavra coordenar significa “ordenar em conjunto”, algo que podemos interpretar como a harmonia na conexão de gestos distintos em um único movimento fluido e contínuo (CARVALHO 1987).

Além disso a coordenação motora também está atrelada a outras capacidades, como a de adaptação a novos estímulos, orientação, percepção espacial, percepção de tempo, transferência de aprendizagem, precisão, ritmo, e o próprio equilíbrio (MARQUES, 1992).

Uma importante parte do envolvimento da coordenação motora com a prática do Skate, e especialmente no Street Skate, está na coordenação motora fina, mais especificamente no controle dos pés e tornozelos. Essas são ações que envolvem pequenos grupamentos musculares e um controle muito preciso do SNC (Sistema Nervoso Central) (PELLEGRINI, 2000). O controle óculo-pedal, que diz respeito à coordenação entre o olho e o pé em relação a algum objeto (LE BOUCH, 1992), é a capacidade responsável pela execução de inúmeras manobras e técnicas do Skate.

## 2.2.5 Aspectos Relativos ao Equilíbrio Humano

Para definirmos a capacidade coordenativa de equilíbrio, primeiro devemos entender aspectos mais abrangentes deste fenômeno, como a gravidade e os aspectos funcionais e anatômicos do organismo humano (NEGRINE, 1987).

A atração que a terra exerce sobre os corpos é chamada de gravidade terrestre e é representada pela constante  $g$ , sendo  $g$  igual a  $9,795 \text{ m/s}^2$ , valor definido para Porto Alegre (latitude  $-30^\circ 01' 59''$  e longitude  $-51^\circ 13' 48''$ ) (DA SILVEIRA, 2006). Chamamos de centro de gravidade quando a resultante das forças gravitacionais sobre um corpo se concentra em um ponto. Sabe-se que quanto mais jovem o indivíduo mais alto se encontra seu CDG, fenômeno causado pela desproporcionalidade entre a parte superior e inferior do corpo infantil, algo que vulnerabiliza o equilíbrio da criança (NEGRINE, 1987).

Em caráter fisiológico o equilíbrio se forma através de contribuições multissensoriais obtidas por três fontes distintas, essas sendo o sistema visual, o sistema proprioceptivo e o aparelho vestibular, que juntos atuam interligados na captação dos estímulos exteriores que por sua vez são processados pelo SNC (DeHart, 1996).

De todos os sentidos relacionados à orientação, a visão é o mais importante. Através da visão que criamos referenciais importantes para nos movimentarmos, é como percebemos o que está acima, e o que está abaixo, direita e esquerda, a

proximidade de objetos em relação ao horizonte e a velocidade com que estes se movimentam pelo espaço (Guyton, 1989).

O sistema proprioceptivo é o responsável pela capacidade cenestésica do indivíduo, ou seja, movimentação e posição do corpo em relação ao espaço. Impulsos nervosos deste sistema podem vir a serem conscientes ou inconscientes, apenas os conscientes estão relacionados com a capacidade de orientação. Os órgãos receptores deste sistema são divididos em exteroceptores, proprioceptores e interoceptores, os exteroceptores são encontrados na superfície externa (pele) e apenas os mecanorreceptores influenciam na capacidade de orientação, os proprioceptores são localizados nos tendões, nas articulações e na musculatura esquelética (fusos musculares, órgãos tendíneos de Golgi, corpúsculos lamelares de Pacini, terminações livres e terminações de Ruffini), os interoceptores são localizados nas vísceras, vasos sanguíneos e artérias, estes não influenciam a capacidade de orientação, fornecendo apenas informações não somáticas (GILLINGHAM; PREVIC, 1996). Os estímulos originados dos exteroceptores e proprioceptores são chamados de somáticos, por serem os responsáveis pela capacidade de cinestesia do corpo (MACHADO, 2013).

O aparelho vestibular é o órgão responsável por detectar mudanças em dois tipos de acelerações, angular e linear, agindo respectivamente a um giroscópio e um acelerômetro. Intimamente relacionado com a força gravitacional terrestre, o aparelho vestibular basicamente nos indica a posição da cabeça (inclinação) em relação as forças que atuam sobre ela, gravidade, através da aceleração da endolinfa que preenche os canais semicirculares, o utrículo e o sáculo, também conhecidos como órgãos otolíticos, pequenos cristais de carbonato de cálcio chamados de otólitos estimulam células ciladas, que se ligam ao nervo vestibular (OLIVEIRA, 1994). Em média 200 impulsos nervosos por segundo são transmitidos ao SNC em repouso, que os utiliza para interpretar a posição e inclinação da cabeça em relação ao solo (OLIVEIRA, 1994).

### 2.3 ACIDENTES E LESÕES NO SKATE

Um desenvolvimento seguro de técnicas de Skate deve ser almejado especialmente com crianças, pois esses indivíduos já possuem um equilíbrio fragilizado devido a características morfofuncionais do corpo infantil (NEGRINE, 1987).

Além disso, skatistas iniciantes possuem pouca coordenação motora sobre o skate, algo que dificulta o equilíbrio e execução de qualquer gesto motor (PELLEGRINI, 2000). Tais fatores podem explicar os estudos epidemiológicos que caracterizam o Skate como um esporte com alto índice de acidentes e lesões



musculoesqueléticas durante sua iniciação (FOUNTAIN; MEYERS, 1996) (KYLE et al, 2002).

Outro fator que influencia a incidência de lesões, especialmente na modalidade Street, é que a fina coordenação motora óculo–pedal responsável pelas manobras mais básicas da modalidade necessitam de extrema coordenação motora e equilíbrio para que sejam executadas corretamente (LE BOUCH, 1992), ambas capacidades coordenativas não muito desenvolvidas em crianças e skatistas iniciantes.

Estudos estatísticos sobre lesões relacionadas ao Skate nos mostram que 52% de todos os traumas ocorrem em crianças com idade inferior a 15 anos (AAOS, 2013). Estudos também mostram que a falta de equilíbrio e a falha ao tentar executar uma manobra, são os principais fatores causadores de lesões no esporte, com um índice de 63% (FORSMAN; ERIKSSON, 2001). Já as lesões mais comuns são associadas a traumas envolvendo as articulações do tornozelo e punho, onde 33% de todos os lesionados pela prática do Skate são praticantes iniciantes durante a primeira semana de prática (FOUNTAIN; MEYERS, 1996).

Everett, (2002), examinou o índice de incidência de acidentes em um skatepark comercial durante um ano, e o estudo mostrou que o índice anual de acidentes foi de 1,11 acidentes por 1000 indivíduos. Resultado inferior a outros estudos similares que examinaram o índice de acidentes fora de skateparks comerciais ou pistas indoor, com 7,0 por 1000 indivíduos. Kyle e colaboradores, (2002), em um estudo similar mostram que em 1998 o índice de acidentes e atendimentos em unidades de pronto–socorro foi de 8,9 por 1000 indivíduos. Podemos interpretar esses dados como indicadores de que a prática do Skate fora de ambientes controlados, como o meio urbano, é mais suscetível à ocorrência de lesões e acidentes.

Geralmente em pistas comerciais de Skate a utilização de equipamentos de segurança (capacete, joelheiras, cotoveleiras, munhequeira) é obrigatória, especialmente para crianças e menores de idade (KYLE et al, 2002)(EVERETT, 2002). Contudo a prática do Street além de se caracterizar por uma prática esportiva de baixo custo (kits de equipamentos de proteção custam ± R\$ 300,00), a modalidade não possui a tradição de se utilizar equipamentos de segurança, especialmente no meio urbano.

Sendo o Skate uma prática esportiva adotada por milhões de crianças e indivíduos pelo mundo, Hetzler e colaboradores, (2011), apontam para a falta de literatura sobre o assunto. Uma pesquisa feita na base de periódicos PubMed® encontrou apenas 48 estudos relacionados a lesões no esporte, um estudo

relacionado os aspectos biomecânicos do skate datado de 1980, e nenhum estudo sobre seus aspectos fisiológicos (HETZLER et al, 2011).

Enquanto o Skate for uma prática onde acidentes são mais prováveis a aqueles mais fragilizados pela idade e desenvolvimento motor, é necessário que sejam desenvolvidas contramedidas para remediar o número de lesões no esporte (MCKENZIE et al, 2016). Métodos que auxiliem no desenvolvimento seguro e pedagógico das habilidades do esporte devem ser almejados por todos os profissionais de educação física da área.

## 2.4 SIMULAÇÕES E EXERGAMES

Com o avanço da tecnologia, cada vez mais experiências interativas e simulações vêm sendo utilizadas como métodos de aprendizagem alternativos, à medida em que a tecnologia é aprimorada novas otimizações se tornam possíveis, trazendo esses métodos cada vez mais próximo do público geral e também da realidade a ser simulada.

*Computer Assisted Assessment (CAA)* é um método de diagnóstico, feedback e motivação, com grande potencial para reforçar experiências de aprendizagem, combinando a natureza interativa das simulações com a disponibilizam conhecimento de resultado (FREEMAN et al, 1998). Entretanto a utilização de CAA, como quase toda inovação tecnológica, é alvo de críticas e ceticismo, pois especulasse que está seja uma maneira pobre de testar as reais capacidades de um indivíduo.

Atualmente jogos interativos são usados para melhorar o desempenho na aprendizagem de inúmeras tarefas, como por exemplo, na fina coordenação motora necessária para se realizar procedimentos cirúrgicos (ALDRICH, 2005) (CHIPMAN; SCHMITZ, 2009) (GARDNER; MSAR, 2008). Simuladores 3D podem oferecer uma rica compreensão de tarefas ou gestos motores complexos, sem a interferência de fatores como a consequência do erro, o medo, a possibilidade de lesão, o desgaste físico que geralmente é menor em simulações, aumentando assim a confiança do indivíduo e o aproximando-o do gesto/fenômeno real (ADI et al, 2010).

Podemos definir simulações como uma espécie de multimídia interativa, com elementos dinâmicos que se encontram em controle do usuário. Um simulador é uma ferramenta que reproduz um fenômeno a ser explicado/entendido pelo utente, assim o usuário tem a oportunidade de interagir com um modelo simulado de maneira segura, adquirindo conhecimento e habilidades necessárias para a execução real da tarefa (RIEBER, 2005).

Um ditado chinês da filosofia Confucionista diz que “Se você me contar, eu vou ouvir, se você me mostrar, eu vou ver, se você me deixar experienciar, eu irei

aprender”. O aprendizado se torna mais enriquecedor quando colocamos em ação o que sabemos, vemos e ouvimos, engajando em experiências de forma ativa, e é isto que conhecemos por interatividade (LEWIN, 1995)(BROOKFIELD, 1986). A interatividade resulta em um aprendizado mais eficiente, pois aprendizes podem testar suas hipóteses, aprender através de seus erros e compreender melhor os fatores que influenciam o fenômeno em questão (KOLB, 1984).

Atualmente jogos e simulações são considerados ferramentas eficientes em motivar e auxiliar aprendizes em seu desenvolvimento. Estudantes que utilizam essas ferramentas relatam se sentirem mais confiantes em relação a suas habilidades quando atuando em situações reais (KE, 2008) (PAPASTERGIOU, 2009) (RONAN; ELIHU, 2000).

Jogos controlados pelo movimento dos usuários, mimetizando gestos e habilidades motoras da vida real, ganharam muita popularidade nos últimos anos. Um console muito conhecido que disponibiliza essa interface é o Nintendo Wii, onde controles especiais utilizam acelerometria e captura de imagem para disponibilizar jogos baseados em movimentações reais. Esses jogos auxiliam na imersão do usuário dentro da simulação, ainda promovendo a prática de atividade física que é benéfica para seus usuários (ANLAUFF et al, 2010).

#### 2.4.1 *Exertion Games* e o Skate.

Encontra-se na literatura a expressão *Exertion Games* ou *Exergames*, utilizada para denominar jogos onde é requisitado o investimento de ação física por parte do usuário (MÜLLER et al, 2008). Estudos já comprovaram que esse tipo de interatividade com simulações pode inclusive auxiliar no aumento da performance de atletas profissionais de patinação e velocidade no gelo (STIENSTRA et al, 2011), remo (BORKER; CRAWLEY, 2001), e natação (MARC et al, 2009).

*Exergames* sobre Skate podem ser encontrados atualmente, porém a maioria desses simuladores não possui uma interface interativa que disponibilize uma simulação realista. Geralmente os controles utilizados por estes jogos não permitem a movimentação do skate/controlador, esse se encontrando em uma posição fixa como podemos ver no exemplo da Figura 8, Top Skater, um jogo tradicional de fliperama da empresa Prime Time Amusements (ADI et al, 2010).

Figura 8 – Simulador de Skate, Top Skater da *Prime Time Amusements*.



Fonte: (ADI et al, 2010).

O *Tilt n' Roll* é um exemplo de *exertion game* onde o tipo de interface utilizada permitiu um maior realismo durante a simulação. No jogo o usuário utiliza um skate real para realizar manobras e assim controlar a simulação. Para esse fim um skate convencional foi equipado com sensores de medição inercial (IMU) que permitiram o monitoramento das acelerações impostas ao skate, que mais tarde eram utilizadas para determinar a manobra realizada. O jogo foi desenvolvido para aparelhos celulares, como mostra a Figura 9, assim podendo ser utilizado em qualquer local próprio para a prática do Skate (ANLAUFF et al, 2010).

Figura 9 – *Tilt n' Roll*, *exertion game* para a prática do Skate.




Fonte: (ANLAUFF et al, 2010).

Os componentes eletrônicos e a bateria do sistema foram acoplados entre a base do eixo e o shape, por esse ser o único lugar no skate livre de golpes e colisões contra o skatista e o próprio ambiente. Elevadores são componentes utilizados para

aumentar a distancia entre o shape e as rodas, comumente usados para aumentar a mobilidade do skate. Foi customizado um elevador de policoreto de vinila (PVC) para a proteção e contenção do sistema de aquisição como pode ser visto na Figura 10 (ANLAUFF et al, 2010).

Figura 10 – Montagem do sistema de aquisição utilizando um elevador de PVC modificado.



Fonte: (ANLAUFF et al, 2010).

Após as tentativas de cada manobra o usuário recebe um feedback audiovisual na tela do celular para auxiliar no processo de aprendizagem. Isso nos mostra com a aplicação de tecnologias simples, como um acelerômetro, podem ser utilizadas para compreender o Skate através de uma linguagem quantitativa é discreta, assim, sendo apta para ser interpretada de maneira digital (ANLAUFF et al, 2010).

## 2.5 UNIDADES DE MEDIÇÃO INERCIAL (IMU)

A utilização de unidades de medição inercial em dispositivos portáteis só se tornou possível após o desenvolvimento tecnológico de sistemas microeletrônicos (MEMS) que permitiram a fabricação de acelerômetros e giroscópios de chip único a baixíssimos custos. Atualmente sensores MEMS incorporam diversos tipos de sistemas, como o de posicionamento global por satélite (GPS), sistemas de navegação inercial e inclusive sistemas para detecção de movimentos (SKOG; HÄNDEL, 2006). Sensores inerciais, como acelerômetros e giroscópios, detectam aspectos diferentes nas acelerações causadas sobre um corpo, essas acelerações nos disponibilizam dados quantitativos para interpretarmos a movimentação de um objeto pelo espaço (TRITSCHLER, 2003).

A aplicação da tecnologia de acelerometria para o desenvolvimento de jogos, simulações, e estudos relacionados à atividade física ainda é uma área aberta para


pesquisa, sendo a acelerometria um método de análise cinemática do movimento onde IMUs são utilizados para detectar mudanças de velocidades produzidas pelo movimento humano (PERRY, 2005)(KIONIX, 2017). No âmbito do Skate poucos estudos exploraram esta tecnologia para o desenvolvimento seja de *exergames*, simuladores mais sofisticados, ou para apenas o estudo do esporte em si (ANLAUFF et al, 2010) (GROH et al, 2015).

A seguir serão apresentados os princípios de funcionamento dos sensores inerciais e a modelagem matemática que descreve a movimentação de um corpo pelo espaço.

### 2.5.1 Sistema de Eixos.

O sistema de coordenadas utilizado para modelarmos o movimento de um corpo pelo espaço consiste de três eixos referenciais,  $x^a, y^a, z^a$ , todos sendo ortogonais, onde qualquer ponto no plano tridimensional pode ser representado como uma combinação dessas três coordenadas e o sentido positivo dos ângulos,  $\omega$ , é medido por convenção no sentido anti-horário, como mostra a Figura 11 (SKOG; HÄNDEL, 2006).

Figura 11 – Sistema de Eixos  $x^a, y^a, z^a$ .



Fonte: (SKOG; HÄNDEL, 2006).

### 2.5.2 Vetores e Matrizes

Se tivermos um ponto sobre um plano bidimensional, composto por dois eixos de coordenadas ortogonais  $(x, y)$  esse ponto pode ser representado por um vetor (associado ao deslocamento de um ponto no espaço para outro em uma direção


específica). Assim, quando nos referimos as coordenadas de um vetor, usamos como referencial o sistema de eixos citado anteriormente.

Mesmo um ponto fixo no espaço,  $P = \begin{Bmatrix} x_0 \\ y_0 \end{Bmatrix}$ , e um vetor,  $\vec{r} = \begin{Bmatrix} x_0 \\ y_0 \end{Bmatrix}$ , representarem conceitos diferentes, ambos são representados na forma matricial pelo mesmo sistema de eixos e coordenadas (CUARELLI, 2013).

Na Figura 12, é ilustrado um ponto  $P(x_0, y_0)$  também representado pelo vetor  $\vec{r}$ , a movimentação desse ponto para a coordenada  $P_1(x_1, y_1)$ , pode ser representada como a soma de um ponto por um vetor  $\vec{v}$ , assim a soma de um ponto por um vetor da origem a outro ponto, da seguinte maneira (Equação 4);

$$[P_1(x_1, y_1) = P + \vec{v} = \vec{u}] \quad (4)$$

Figura 12 – Deslocamento de um ponto representado pela soma do ponto  $P(x_0, y_0)$  pelo vetor  $\vec{v}$ .



Fonte: (CUARELLI, 2013).

A partir dos vetores correspondentes à velocidade angular e à aceleração linear nos três eixos do espaço,  $x^a, y^a, z^a$ , é possível determinar o movimento realizado por qualquer corpo em relação a este sistema de coordenadas inicial (CAO; ZU, 2010)(JITAO, 2008)(WANG, et al, 2003)(CHEN, et al., 1994).


### 2.5.3 Transformações Geométricas

Uma transformação geométrica pode ser descrita como a correspondência entre pontos de um mesmo plano ou de planos diferentes. Movimentos realizados por um corpo no espaço podem ser interpretados como a combinação de duas transformações geométricas distintas, a translação e a rotação (BEER; JOHNSTON, 1994).

A translação ocorre quando qualquer reta ligando dois pontos de um determinado corpo conservam a mesma direção durante o deslocamento desse pelo espaço, sendo esta trajetória reta ou curvilínea (Figura 13a). Já o movimento de rotação ocorre quando os pontos que formam o corpo se deslocam circularmente,

sendo o centro dessa circunferência o eixo de rotação do corpo (Figura 13b) (BEER; JOHNSTON, 1994).

Figura 13 – Movimento de Translação (a) e Movimento de Rotação (b).




Fonte: (SILVA, 2013).

### 2.5.3.1 Translação

A translação é uma transformação isométrica que pode ser definida como a resultante de um deslocamento onde o corpo não rota de uma posição a outra, assim podemos dizer que a translação é determinada por uma direção, um sentido, e uma distância (HALLIDAY, et al, 2008). Como exemplo, a Figura 14 demonstra a mudança de posição de um ponto  $A$  para o ponto  $B$ , onde a medida do deslocamento é dada por (Equação 5);

$$s = B - A \quad (5)$$

Figura 14 – Translação do ponto  $A$  para o ponto  $B$ .



Fonte: (SILVA, 2013).

Chamamos de velocidade média a razão entre o deslocamento  $s$  e o intervalo de tempo  $\Delta t$ , podendo ser expressada pela Equação 6;

$$v_{méd} = \frac{s}{t_B - t_A} \quad (6)$$

Onde  $t_B$  e  $t_A$  correspondem aos instantes de tempo que o ponto ocupou as posições  $B$  e  $A$ . Podemos obter a velocidade de um corpo em um determinado instante quando



aproximamos a velocidade média a um valor limite, onde o intervalo de tempo  $\Delta t$ , tende a zero (Equação 7);

$$v = \lim_{\Delta t \rightarrow 0} \frac{s}{\Delta t} = \frac{ds}{dt} \quad (7)$$

Vemos então que a velocidade é a taxa de mudança de posição em relação ao tempo, ou seja, a velocidade é a derivada da posição em respeito à  $t$  (HALLIDAY et al, 2008).

Semelhante ao conceito sobre a velocidade média, podemos obter a aceleração média de um corpo, ou seja, a variação da velocidade em relação a um intervalo de tempo, pela Equação 8;

$$a_{méd} = \frac{\Delta v}{\Delta t} \quad (8)$$


E para obtermos a aceleração instantânea utilizamos a Equação 9 (HALLIDAY et al, 2008);

$$a = \frac{dv}{dt} \quad (9)$$

Tanto no movimento de translação quanto o de rotação, posição, velocidade e aceleração são grandezas vetoriais que indicam diferentes características de um corpo em movimento pelo espaço, contudo estas características só podem ser avaliadas quando comparadas com algum referencial (HALLIDAY et al, 2008). Um mesmo ponto pode ser representado por referenciais diferentes, possuindo coordenadas diferentes também, como por exemplo, na Figura 15 o ponto  $p$  é representado por dois sistemas

de coordenadas diferentes,  $Q_p = \begin{bmatrix} Q_{px} \\ Q_{py} \\ Q_{pz} \end{bmatrix}$  e  $R_p = \begin{bmatrix} R_{px} \\ R_{py} \\ R_{pz} \end{bmatrix}$  (CUARELLI, 2013).

Figura 15 – Ponto  $p$  representado por dois referenciais diferentes, sistema de coordenadas  $Q_p$  e  $R_p$ .



Fonte: (CUARELLI, 2013).

O movimento de um corpo pelo espaço pode ser medido através de sua mudança de coordenadas em relação a um referencial fixo, este processo é definido pela adição e subtração de vetores, como é demonstrado na Figura 15. Um exemplo de deslocamento em um sistema de coordenadas tridimensionais de um ponto  $a_1$  para o ponto  $a_2$  seria representado pela adição do ponto inicial por um vetor  $\vec{p}$ , como mostra a Equação 10;

$$q_2 = \begin{bmatrix} q_{2x} \\ q_{2y} \\ q_{2z} \end{bmatrix} = \begin{bmatrix} q_{1x} \\ q_{1y} \\ q_{1z} \end{bmatrix} + \begin{bmatrix} \vec{p}_x \\ \vec{p}_y \\ \vec{p}_z \end{bmatrix} \quad (10)$$

Na forma matricial, podemos representar a translação de um ponto em um plano da seguinte maneira (Equação 11);

$$\begin{bmatrix} x_1 \\ y_1 \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} p_1 \\ p_1 \end{bmatrix} \quad (11)$$

Assim, se utilizássemos um vetor nulo,  $p = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$ , a translação obtida do ponto  $\begin{bmatrix} x \\ y \end{bmatrix}$ , sendo  $T$  a matriz quadrada de identidade,  $T = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ , o movimento é zero e não ocorre translação ou outra transformação geométrica (Equação 12)(CUARELLI, 2013);

$$\begin{bmatrix} x_1 \\ y_1 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} \quad (12)$$

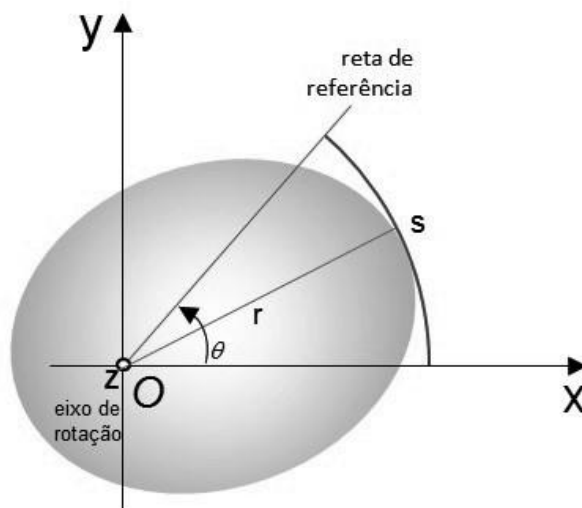
### 2.5.3.2 Rotação

Na rotação, também conhecida como movimento angular, os pontos que formam o corpo se movimentam em uma circunferência em torno de um eixo de

rotação. Nesse tipo de deslocamento todos os pontos percorrem o mesmo ângulo no mesmo intervalo de tempo, e as grandezas vetoriais destacadas no movimento de translação (posição, velocidade e aceleração), possuem equivalentes angulares que podem ser medidos (BEER; JOHNSTON, 1994).

Similar ao movimento de translação, também podemos medir a movimentação angular de um corpo utilizando uma reta de referência fixa perpendicular ao eixo de rotação, a posição angular  $\theta$  dessa reta de referência corresponde ao ângulo entre a reta de referência e outra reta fixa qualquer como posição angular zero, como por exemplo, o eixo  $x$  (Figura 16). O valor de  $\theta$  é uma resultante de  $\frac{s}{r}$ , onde  $s$  é o comprimento da circunferência entre o eixo  $x$  e a reta de referência, e  $r$  é o raio da circunferência realizada pelo corpo em rotação (SILVA, 2013).

Figura 16 – Posição angular de uma reta de referência em relação ao eixo  $x$ .



Fonte: (SILVA, 2013).

Para medirmos as grandezas de velocidade e aceleração angular de um corpo em movimento de rotação utilizamos os mesmos conceitos apresentados na derivação das grandezas lineares relacionadas ao movimento de translação. Desta maneira obtemos a equação de velocidade angular média,  $\omega$ , a partir da Equação 13;

$$\omega = \lim_{\Delta t \rightarrow 0} \frac{\Delta \theta}{\Delta t} = \frac{d\theta}{dt} \quad (13)$$

A aceleração angular média é obtida através da Equação 14;

$$a_{méd} = \frac{\Delta\omega}{\Delta t} \quad (14)$$

E a aceleração instantânea é dada pelo limite da variação de velocidade angular  $\Delta\omega$  quando  $\Delta t$  tende a zero (Equação 15) (HALLIDAY et al, 2008);


$$a = \lim_{\Delta t \rightarrow 0} \frac{\Delta\omega}{\Delta t} = \frac{d\omega}{dt} \quad (15)$$

Como no movimento de translação, a rotação é uma transformação geométrica que não altera as dimensões do corpo, transformação isométrica (SANTOS, 2008). Se utilizarmos o mesmo exemplo da Equação 12, onde um ponto é multiplicado por um vetor nulo, substituindo agora a matriz identidade pela matriz  $T = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$ , obtemos a Equação 16;

$$\begin{bmatrix} x_2 \\ y_2 \end{bmatrix} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix} = \begin{bmatrix} -y_1 \\ x_1 \end{bmatrix} \quad (16)$$

O resultado seria uma rotação de 90 graus em torno da origem do sistema de coordenadas como mostra a Figura 17 (CUARELLI, 2013).

Figura 17 – Deslocamento de 90° de um ponto no plano x, y.




Fonte: (CUARELLI, 2013).

#### 2.5.4 Equação de saída de um sensor inercial.

Para determinarmos às grandezas vetoriais correspondentes a velocidade e aceleração de um corpo e como esse se desloca pelo espaço ,direção e sentido, utilizamos a equação do movimento relativo, onde utilizamos um referencial fixo e um referencial móvel, onde a posição inicial do corpo em movimento corresponde ao ponto zero do sistema de coordenadas utilizado como referencial móvel, como é ilustrado na Figura 18 (SILVA, 2013)(CAO; ZU, 2010)(QIN et al, 2009)(JINTAO, 2008)(WANG et al, 2003)(Chen et al, 1994).

Figura 18 – Representação geométrica da equação do movimento relativo.



Fonte: (SILVA, 2013).

A expressão matemática que representa este deslocamento com base em dois sistemas de referência é dada pela Equação 17;

$$\ddot{r}_B = \ddot{r}_A + \ddot{r}_{B/A} + \dot{\omega} \times r_{B/A} + \omega (\omega \times r_{B/A}) + 2\omega \times \dot{r}_{B/A} \quad (17)$$

onde:  $\ddot{r}_{B/A}$  representa a aceleração do ponto  $B$  em relação ao referencial móvel ( $i$ -frame),  $\ddot{r}_A$  é a aceleração de  $A$  em relação ao referencial fixo, e  $\omega$  é a velocidade angular do referencial móvel em relação ao referencial fixo (SILVA, 2013).

Se por exemplo utilizarmos uma unidade de medição inercial (acelerômetro) posicionada no ponto  $B$  da Figura 21, percebemos que não ocorreria um movimento relativo entre o IMU e o corpo em deslocamento, por tanto os termos  $\ddot{r}_{B/A}$  e  $2\omega \times \dot{r}_{B/A}$  podem ser removidos, simplificando a equação de movimento relativo para a Equação 18;

$$\ddot{r}_B - g = \ddot{r}_A + \dot{\omega} \times r_{B/A} + \omega (\omega \times r_{B/A}) - g \quad (18)$$

onde:  $g$  é o vetor correspondente a aceleração gravitacional imposta sobre o referencial móvel.

Se o acelerômetro for posicionado com o vetor de localização  $u$  e o vetor de orientação  $\theta$ , em um referencial móvel em relação a um referencial fixo ( $b$ -frame), a expressão matemática que representa a saída do sensor é dada pela Equação 19;

$$A(u, \theta) = \langle \ddot{r}_B - g, C_b^i \theta \rangle \quad (19)$$

onde:  $C_b^i$  representa a matriz de transformação dos referenciais móveis para um referencial fixo (SILVA, 2013). A partir das Eq. (18) e (19), a saída do sensor passa a ser a Equação 20;

$$A(u, \theta) = (u \times \theta)^T \dot{\omega} C_{ib}^b + \theta^T (\Omega_{ib}^b)^2 u + \theta^T L^b \quad (20)$$

onde:  $\dot{\omega} C_{ib}^b$  é o vetor de aceleração angular no referencial móvel,  $L^b = (\ddot{r}_A - g)$  é a força específica do referencial móvel, e  $\Omega_{ib}^b$  representa a matriz antissimétrica correspondente ao vetor de velocidade angular  $\omega_{ib}^b = [\omega_{ibx}^b \ \omega_{iby}^b \ \omega_{ibz}^b]$  (SILVA, 2013), representado pela matriz (Equação 21);

$$\Omega_{ib}^b = \begin{bmatrix} 0 & -\omega_{ibz}^b & \omega_{iby}^b \\ \omega_{ibz}^b & 0 & -\omega_{ibx}^b \\ -\omega_{iby}^b & \omega_{ibx}^b & 0 \end{bmatrix} \quad (21)$$

O primeiro e segundo termo do lado direito da Equação 20 se referem aos movimentos angulares (rotação), enquanto o terceiro termo corresponde aos movimentos lineares (translação). A equação de saída obtida mostra que os dois tipos de movimentações podem ser medidas com um conjunto de sensores IMU que detectem as respectivas acelerações nos determinados eixos de interesse (SILVA, 2013 apud QIN et al, 2009).

### 2.5.5 Acelerômetros


Acelerômetros são sensores formados por uma parte sensitiva complementada com circuito eletrônico. Esse circuito eletrônico chamado de transdutor é responsável por transformar um fenômeno físico em um sinal elétrico adequado para ser processado (PAZOS, 2002), sendo à saída deste sistema uma representação de uma grandeza física, como a aceleração no caso de acelerômetros (KIONIX, 2017).

Existe uma grande variedade de acelerômetros disponíveis atualmente, cristais piezoelétricos, sensores piezo resistivos, sensores eletrônicos entre outros compõem uma das famílias mais variadas de sensores utilizados pela indústria (KIONIX, 2017). O mecanismo mais elementar utilizado para medir a aceleração e descrito pela literatura como um sistema massa–mola, onde quando o sistema acelera a inércia faz com que a massa resista, gerando uma força que é contrabalaneada pela mola, tornando o deslocamento da mola proporcional à força aplicada (aceleração), conforme os princípios da Lei de Hooke (Equação 22) onde;

$$F = k. x \quad (22)$$

F sendo a força,  $k$  a constante elástica da mola e  $x$  a deformação da mola. Desde que as forças de aceleração ocorram na direção do eixo  $x$ , como demonstrado na Figura 19, a aceleração do corpo é proporcional a aceleração do conjunto massa–mola (CUARELLI, 2013).

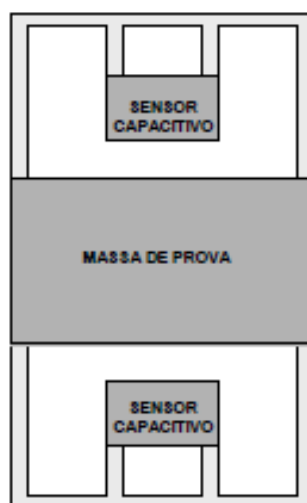
Figura 19 – Sistema massa–mola com sensor para medir aceleração com base na deformação da mola.



Fonte: (CUARELLI, 2013)

Para a aplicação visada neste estudo serão utilizados IMU que utilizam tecnologia MEMS, onde acelerômetros e giroscópios são integrados em um único chip, fato que minimiza o nível de ruído captado pelo sistema e o custo de fabricação do sensor (STMICROELECTRONICS, 2016). Acelerômetros MEMS (Figura 20), utilizam um sistema onde sensores capacitivos medem o deslocamento de uma massa de prova, e transformam este deslocamento em um sinal elétrico correspondente a aceleração da massa de prova (CUARELLI, 2013).


Figura 20 – Ilustração de um acelerômetro MEMS.



Fonte: (CUARELLI, 2013).

Em aplicações onde a gravidade é presente durante toda a aceleração do sistema, acelerômetros são utilizados para indicar mudanças no ângulo de inclinação em relação ao tempo, entre alguns exemplos podemos citar, detecção de horizonte em câmeras digitais, sistemas de navegação inercial, aplicações médicas e desenvolvimento de jogos (KIONIX, 2017). A Figura 21 mostra um acelerômetro bi-axial onde a força gravitacional é expressa como um vetor no eixo z, onde a ausência de aceleração indica que o sensor se encontra na posição horizontal (CUARELLI, 2013). Quando o sensor se encontra nessa posição a inclinação do corpo do sensor é medida através da projeção da força gravitacional sobre os demais eixos do acelerômetro (KIONIX, 2017).

Figura 21 – Acelerômetro MEMS bi-axial na posição horizontal.



Fonte: (CUARELLI, 2013).

### 2.5.6 Giroscópios

O giroscópio fora inventado por Léon Foucault em 1842, o aparato consiste basicamente de uma roda livre, ou múltiplas rodas, que giram em qualquer direção previamente orientada, e possuem a propriedade de se opor a qualquer força que tente mudar sua orientação original, fenômeno conhecido como efeito de Coriolis (HALLIDAY et al, 2008). Praticamente todos os giroscópios MEMS se aproveitam do efeito de Coriolis, que causa uma transferência de energia entre a rotação do sistema e a oscilação da massa de prova, que sofre uma força na direção ortogonal ao sentido de rotação do sistema (BARBOUR; SCHMIDT, 2001).

Atualmente a literatura apresenta diversos tipos de giroscópios, estes classificados fundamentalmente em quatro categorias;

- Giroscópios tipo diapasão (*tuning fork*) – que são constituídos por dois giroscópios do tipo massa-oscilante;
- Giroscópios de rodas oscilantes (*spinning vibrating wheels*);
- Giroscópios de Foucault – baseados nos pêndulos de Foucault;

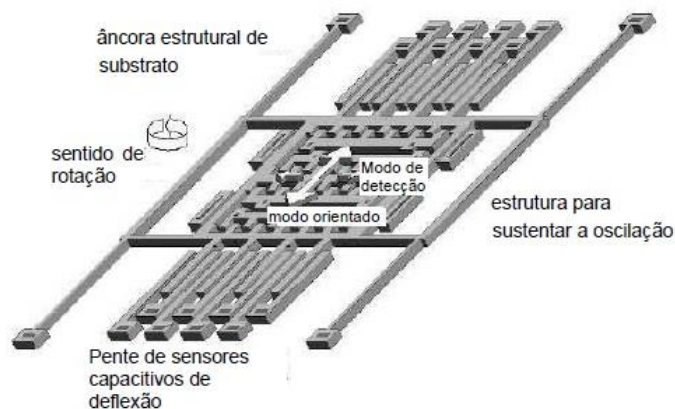


- Giroscópios Hemisféricos Ressonantes – engloba o *wine glass resonator*, o cilindro ressonante e o anel ressonante, por possuírem o funcionamento similar (BARBOUR; SCHMIDT, 2001).

Giroscópios do tipo diapasão são formados por duas massas de prova que oscilam em igual amplitude e direção, porém com sentidos opostos. Quando o movimento de rotação ocorre à força de Coriolis cria uma oscilação em sentido ortogonal na massa de prova, a amplitude da vibração da massa de prova pode ser medida como um sinal elétrico que caracteriza o a aceleração angular do sensor (YOON et al., 2007)

A Figura 22 mostra um diagrama representativo de uma estrutura de silício cristalino, que age como a parte sensitiva de um giroscópio de diapasão.

Figura 22 – Giroscópio de diapasão, fabricado em silício cristalino pelo processo de dissolução da lâmina de silício.




Fonte: (CUARELLI, 2013).

Já um giroscópio do tipo rodas oscilantes, uma roda atua oscilando em seu eixo axial de simetria, e ao ocorrer uma rotação em torno do plano axial a roda sofre uma inclinação para fora do seu plano original. Essa inclinação pode ser detectada através de eletrodos capacitivos localizados embaixo da roda, que permitem a detecção de rotação em dois eixos com apenas uma roda oscilante (GEIGER et al., 2002).

Similar ao giroscópio do tipo roda oscilante, o giroscópio pêndulo de Foucault utiliza um atuador (nesse caso um pêndulo) suspenso por uma haste orientada fora do plano de referência da estrutura, que oscila conforme a inclinação do sistema. Atuais avanços na tecnologia de MEMS permitem a fabricação de pêndulos que não necessitam acoplamento manual da haste, tarefa extremamente complexa quando utilizando instrumentos de fabricação planar (GEIGER et al., 2002) (STMICROELECTRONICS, 2016).

Por último, o giroscópio hemisférico ressonante (Figura 23) possui como atuador um anel ou cilindro suspenso por molas localizadas a  $45^\circ$  de inclinação da posição referencial do atuador. O movimento oscilatório do atuador descreve um formato elíptico, que na presença de uma rotação perpendicular ao plano de vibração original, o anel oscila fora do eixo, esta oscilação causa uma tensão que é detectada pelas molas condutoras (BERNSTEIN, 2003).


Figura 23 - Imagem de microscopia eletrônica de varredura de um giroscópio tipo anel ressonante suspenso por um campo eletromagnético.



Fonte: (BERNSTEIN, 2003).

Giroscópios servem como referenciais de direção, porém não de posição. Por este fato usualmente são utilizados de dois, a três giroscópios posicionados em eixos ortogonais, para que sejam detectadas as variações de inclinação e rotação em todos os eixos de interesse, como mostra a Figura 24, onde diversos sensores são utilizados para integrar uma única unidade de medição inercial (CUARELLI, 2013).

Figura 24 – IMU composta por acelerômetros e giroscópios que detectam aceleração linear e angularem múltiplos eixos (X, Y, Z).



Fonte: (SKOG; HÄNDEL, 2006).

### 2.5.7 Utilização de IMU no Skate

No desenvolvimento do jogo *Tilt n' Roll*, Anlauff e colaboradores (2010) criaram um sistema de aquisição composto por diferentes sensores controlados por um microcontrolador Atmel de 8-Bits, o sistema era alimentado por uma bateria de polímero lítio-íon (LIPO) recarregável, a transmissão de dados para o smartphone que executava o jogo era realizada por protocolo Bluetooth.

O sistema completo de sensores era formado por um acelerômetro tri-axial, um giroscópio tri-axial, sendo coletadas simultaneamente seis dimensões do mesmo movimento. Um sensor de pressão (FSR) instalado embaixo da lixa do skate foi utilizado para determinar acerto da manobra. Sensores foram amostrados a aproximadamente 70 amostras/s, assim mudanças de aceleração de até 35 amostras/s podiam ser medidas (ANLAUFF et al, 2010).

A primeira etapa no processo de detecção e classificação de manobras consistia em detectar o intervalo de tempo em que o skatista realizava alguma manobra, foram utilizados os sinais de saída do canal correspondente ao eixo-Y (vertical) de aceleração, devido a característica elevação do *nose* previamente a execução das manobras utilizadas no desenvolvimento do jogo (Ollie e Frontside Ollie 180°) (ANLAUFF et al, 2010). Uma janela de 0.5s rastreou pelos dados disponibilizados pelo sensor picos de aceleração do eixo-Y acima de certo limite, que indicavam eventos a serem classificados (ANLAUFF et al, 2010).


Para a classificação das manobras foi utilizada uma Análise Discriminante Linear (LDA) com um janelamento de 0.5 segundos. O LDA foi modelado através de um banco de dados composto por 20 manobras coletadas de cada classe (Ollie e Frontside Ollie 180°) pelos sete sensores disponíveis. LDA resulta em um valor escalar onde o sinal é usado para diferenciar duas classes de padrões, e já que a formulação padrão da LDA só lida com problemas que possuem dois resultados, um-ou-outro, o método foi bem-sucedido em diferenciar os dois tipos de manobras (ANLAUFF et al, 2010).

A técnica utilizada para detecção e classificação de manobras obteve uma alta taxa de reconhecimento, com índices de acerto > 90%. O método foi considerado computacionalmente eficiente pelos autores, que relatam a disponibilidade de tempo real do aplicativo em smartphones modernos (ANLAUFF et al, 2010).

Já em um estudo mais recente, realizado por Groh e colaboradores (2015), sensores IMU combinados com um algoritmo de detecção de manobras e quatro métodos de classificação diferentes foram usados para classificar seis tipos de manobras, Ollie, Nollie, Kickflip, Heelflip, Pop Shove it e 360-flip.

Foi utilizado como sensor o sistema miPod que possui entre seus componentes uma unidade de medida inercial (acelerômetro e giroscópio tri-axial), com uma escala ajustada para  $\pm 16g$  e  $2000^\circ/s$ . As medidas foram realizadas com uma resolução de 16-bits por eixo, e o sinal amostrado em 200 amostras/s. A unidade de medição inercial foi acoplada posteriormente ao eixo dianteiro do skate, dessa maneira a direção dos eixos do IMU são orientados como mostra a Figura 25 (GROH et al, 2015).

Figura 25 – Diagrama de orientação dos eixos da IMU acoplada ao skate.



Fonte: (GROH et al, 2015).

Para a detecção das manobras o sinal dos sensores inerciais foram janelados em intervalos de 1 segundo com uma sobreposição de 0.5 segundos, tempo estipulado para que ocorra uma manobra completa (salto, voo, e aterrissagem). Quando uma janela possui uma energia que excedesse um valor limite, energia relacionada ao impacto gerado pela aterrissagem do skate, a janela passa a corresponder a um evento detectado, esse evento é registrado por um intervalo de tempo  $[t_{Land} - 1s]$  até  $[t_{Land} + 0.5s]$ , em seguida o intervalo é processado para o reconhecimento de padrões (GROH et al, 2015).

Todos os padrões de aceleração respectivos aos seis referenciais inerciais disponibilizados pelo sensor, os valores normalizados dos acelerômetros e giroscópios, e também a correlação de X – Y, X – Z, e Y – Z foram calculadas para cada eixo. Dessa maneira cada janela de interesse gerava 54 características de reconhecimento para a etapa de classificação (GROH et al, 2015).

Ambas a seleção e classificação de padrões foram realizados pelo *Embedded Classification Software Toolbox* (ECST), os padrões de aceleração selecionados para classificação foram identificados através de quatro classificadores diferentes, Bayes Ingenuo (NB), Árvore de Decisão Parcial (PART), Máquina de Vetor de Suporte (SVM) com um kernel de base radial e o K-vizinho mais próximo (kNN), a eficiência e esforço computacional de cada classificador foi avaliada (GROH et al, 2015).

O algoritmo de detecção foi capaz de apontar corretamente 323 dos 343 eventos, resultando em uma sensibilidade de 94,2%, enquanto os melhores classificadores foram o NB e o SVM com precisão de 97,8%, contudo o método Bayes Ingenuo gerou um esforço computacional muito menor (360 operações/6.2s) que o classificador SVM (1015 operações/32.7s) (GROH et al, 2015).

Os autores do estudo reconhecem o êxito em utilizar a acelerometria para quantizar e detectar manobras de Skate. Contudo, ressaltam a necessidade de aprofundamento no tema para que classificadores mais eficientes possam gerar aplicações em tempo real (GROH et al, 2015).

Métodos de classificação de manobras que abranjam a variedade de técnicas existentes no Street Skate, e possam ser aplicados em tempo real, ainda necessitam de pesquisa e desenvolvimento, sendo a acelerometria uma solução parcial para esta tarefa.

## 2.6 REDES NEURAS ARTIFICIAIS E CLASSIFICAÇÃO DE PADRÕES

Uma das principais aplicações para Redes Neurais Artificiais (RNAs) e conceito de aprendizagem de máquina encontrasse na tarefa de classificar padrões de entrada em diferentes classes ou categorias (BENGIO et al, 2012).

Classificação consiste na rotulação de amostras de entrada através de algum critério escolhido pelos criadores do sistema. Redes neurais são capazes de classificar padrões desconhecidos em categorias previamente estabelecidas ou categorizar sem referência alguma. RNAs aprendem com exemplos, melhoram com a experiência adquirida, e podem utilizar sua memória para auxiliar na resolução de problemas futuros (HAYKIN, 2001).

RNAs são consideradas processadores constituídos por diversas unidades de processamento mais simples organizadas em paralelo, numa rede que como o cérebro humano possui uma propensão natural em reter experiências de aprendizado e utilizá-las quando necessário, algumas das características mais específicas de redes neurais são (HAYKIN, 2001);

- Capacidade de interpretar o comportamento não linear de fenômenos físicos;
- Aprender através de exemplos (entradas) que sejam representativas;

- Aprender sem referências;
- Armazenar o conhecimento adquirido;
- Adaptabilidade;
- Generalizam o conhecimento aprendido para acelerar a resolução da tarefa proposta.

Atualmente aprendizado de máquina é empregado como uma eficaz solução para problemas nos mais diversos campos do conhecimento. Na área biomédica redes neurais são utilizadas em situações como o reconhecimento biométrico (faces, íris, impressões digitais), reconhecimento de imagens e classificação de padrões para diagnóstico, e na biomecânica para o reconhecimento e classificação de gestos motores (BENGIO et al, 2012).

A utilização de algoritmos para a classificação e reconhecimento de padrões é uma área muito desenvolvida pela literatura, onde diversas técnicas são disponíveis atualmente, tais como;

- a) Redes Neurais Artificiais (BENGIO et al, 2012);
- b) Árvores de Decisão (ERMES et al, 2008);
- c) Limiares e Regras de Conhecimento a Priori (KARANTONIS et al, 2006);
- d) Máquinas de Vetores de Suporte (GYLLENSTEN, 2010);
- e) Classificador de Bayes Ingênuo (BAO; INTILLE, 2004);
- f) K-vizinhos mais próximos (GROH et al, 2015);
- g) Modelos Ocultos de Markov (Wang et al, 2011).

Para este estudo foi escolhido o método de classificação por RNA para categorizar as manobras realizadas pelo simulador, a seguir serão revisados os conceitos teóricos envolvendo Redes Neurais Artificiais, assim como os tipos mais comuns de redes existentes e seus métodos de aprendizagem.

### 2.6.1 O cérebro humano

Quando comparado com um computador digital convencional, o cérebro humano processa informações de uma maneira muito distinta. Utilizando a maleabilidade da estrutura neuronal, o cérebro é capaz de reestruturar suas interconexões sinápticas para melhor atender a situação, mostrando alta adaptabilidade ao se desenvolver intrincados mecanismos de aprendizagem que se adaptam conforme novas experiências são assimiladas (HECTH, 1998).

O SNC é formado por um conjunto extremamente complexo de neurônios, este conjunto de células nervosas é responsável por toda a experiência humana e como a compreendemos. O neurônio em si é formado por dendritos, que agem como terminal

de entrada do sistema pelo corpo da célula (soma), que une os dendritos aos axônios, esses que são os terminais de saída.

Neurônios se comunicam entre si através da troca de neurotransmissores por intermédio das sinapses, sendo essa a área onde o axônio de um neurônio se liga ao dendrito de outro neurônio. O estímulo gerado pela ação dos neurotransmissores gera o potencial de ação que causa uma despolarização, impulso nervoso, pelas células do cérebro. Esse é um processo que depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor. O cérebro humano possui cerca de  $8.6 \times 10^9$  neurônios, com um número de sinapses que ultrapassa  $100 \times 10^{12}$ , magnitudes que mostram a complexidade por trás do cérebro humano (HAYKIN, 2001).

RNA é um método inspirado nas amplas capacidades do cérebro humano, contudo as mais complexas redes neurais artificiais ainda são mecanismos extremamente simples quando comparados ao modelo original. A abordagem das RNAs se baseiam na habilidade de processamento de informação do cérebro, problemas onde uma solução para uma determinada tarefa pode ser alcançada através do treinamento (aprendizado de máquina) (BEALE; JACKSON, 1990).

Hecht (1998) fornece uma definição formal para o conceito de RNA como;

...uma estrutura de processamento de informações distribuída e paralela. Ela é formada por unidades de processamento, comumente chamadas de nós, neurônios ou células, interconectadas por arcos unidirecionais, também chamados de ligações, conexões ou sinapses. Os nós possuem memória local e podem realizar operações de processamento de informação localizada. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada ramificação possuindo o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula.

## 2.6.2 Propriedades e Características de RNAs

A estrutura das RNA é formada por grafos e diversas unidades de processamento chamadas de neurônios, cada neurônio é formado por três elementos principais, estes sendo os elos de conexão (sinapses), o limiar (*bias*) e a função de transferência. Cada sinapse possui um próprio peso, denominado de força de conexão, onde o valor aplicado à sinapse de entrada será multiplicado pelo peso sináptico antes de alcançar a soma da célula, que é responsável pela combinação linear de todas as entradas (HAYKIN, 2001).

A função de transferência ( $\varphi$ ) é responsável por processar o sinal gerado pela combinação linear de todas as entradas e pesos sinápticos, e gerar o sinal de saída da célula em termos do campo induzido ( $v$ ), as três funções de transferências mais elementares são a função de limiar (a), função de limiar por partes (b), e a função sigmoide (c) que são ilustradas na respectiva ordem pela Figura 26. As funções de transferência citadas possuem as seguintes características (HAYKIN, 2001):

Função de limiar: a saída da célula é igual a um quando seu valor for positivo, e zero quando seu valor for negativo (Equação 22):

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (22)$$

Função de limiar por partes: tipo de função que pode ser descrita com uma aproximação de um amplificador linear (Equação 23):

$$\varphi(v) = \begin{cases} 0 & \text{se } v \geq -0,5 \\ \frac{v}{2} & \text{se } -0,5 > v > +0,5 \\ 1 & \text{se } v \leq +0,5 \end{cases} \quad (23)$$

Função sigmóide: função de transferência mais usada em RNA é descrita como uma função estritamente crescente que apresenta um balanço entre o comportamento linear e não-linear. Um exemplo de função sigmoide é a função logística (Equação 24):

$$\varphi(v) = \frac{1}{1+e^{(-v/T)}} \quad (24)$$

Onde  $T$  determina inclinação da sigmoide, conforme  $T$  tende a zero a função se torna limiar.


Se necessário que a função de transferência possua um formato anti-simétrico em relação a origem, valores entre  $[-1,+1]$ , utiliza-se a função tangente hiperbólica usualmente (Equação 25):



$$\varphi(v) = \frac{1 - e^{-av}}{1 + e^{+av}} \quad (25)$$

Onde  $a$  é o parâmetro de inclinação da sigmóide.

Figura 26 – Funções de transferência: Função de limiar (a), Função de limiar por partes (b), função sigmóide (c).



Fonte: O autor (2017).

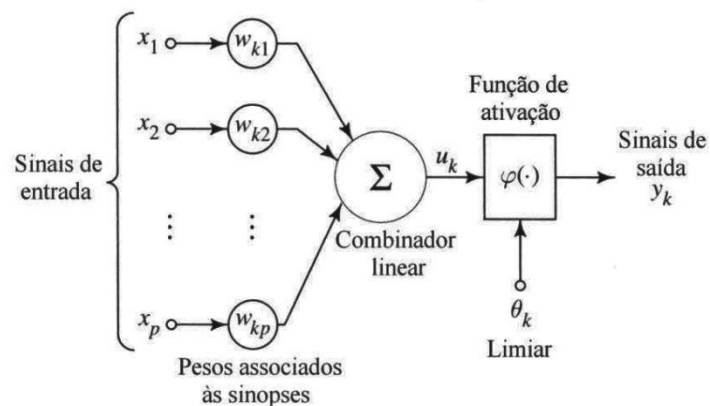
RNAs podem possuir diversos tipos de funções de transferência, o *Neural Patter Recognition App* disponível no *Neural Network Toolbox* do software MATLAB utiliza de 16 funções de transferência para modelar padrões e sinais, como *soft max*, *logistic*, *tan sigmoid*, *competitive*, entre outras.

O modelo matemático que representa a teoria das redes neurais artificiais é representado na Figura 27, onde são destacados os sinais de entrada  $x_j = (x_1, x_2 \dots x_p)$ , os pesos sinápticos das conexões ( $W_{kj}$ ), o limiar (bias) ( $\theta_k$ ), a função de transferência ( $\varphi$ ), o combinador linear de entrada ( $\Sigma$ ), e os sinais de saída do sistema ( $y_k$ ). Podemos descrever um neurônio  $k$  através das Equações 26 e 27 (HAYKIN, 2001).

$$u_k = \sum_{j=1}^p W_{kj} x_j + \theta_k \quad (26)$$

$$y_k = \varphi(u_k) \quad (27)$$

Figura 27 – Representação matemática de um neurônio artificial ( $k$ ).



Fonte: (HAYKIN, 2001).

### 2.6.3 Tipos de Redes Neurais Artificiais

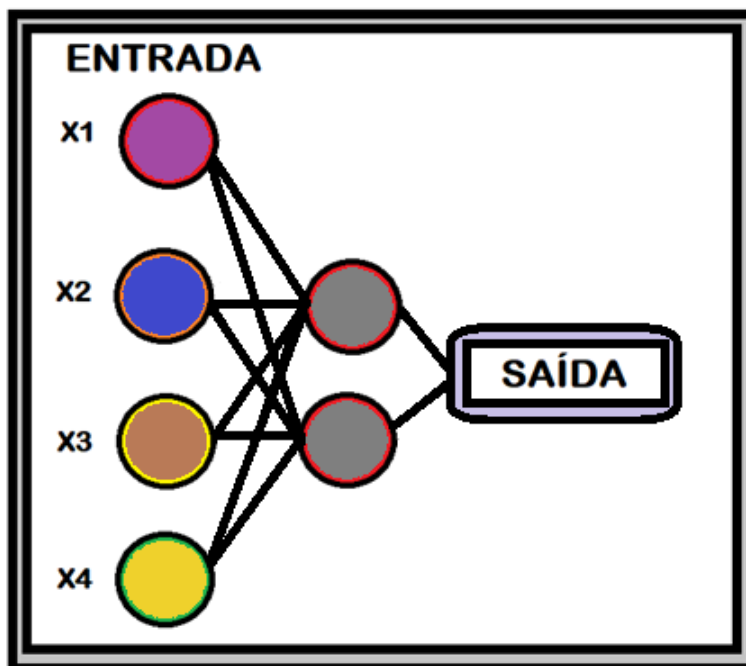
Redes neurais são desenvolvidas em diversos modelos, onde a arquitetura e algoritmos de treinamento de cada tipo as diferem dos demais. A arquitetura de uma RNA se refere ao modo como os neurônios são estruturados, enquanto o algoritmo é o conjunto de regras que visa o aprendizado e melhoria do desempenho da rede neural em sua determinada função (REZENDE et al, 2003).

A maioria das RNAs possuem duas diferentes etapas durante seu desenvolvimento, o treinamento e a validação. Na etapa de treinamento a rede neural ajusta os valores dos pesos sinápticos através do uso de algum algoritmo de treinamento. Já na etapa de validação, com base na experiência acumulada a RNA calcula os valores de saída com base nas entradas e nos pesos pré-estabelecidos. Podemos ressaltar três tipos de RNAs mais revisadas pela literatura: Redes Diretas de Uma Camada (*Single-Layer Feed Forward Network*); Redes Diretas de Multicamadas (*Multilayer Feed Forward Network*); e Redes Recorrentes (*Feed Backward*) (HAYKIN, 2001).

#### 2.6.3.1 Redes Diretas de uma Camada (*Single-Layer Feed Forward Network*)

São RNAs de apenas uma camada de entrada ligada aos neurônios de saída, também conhecidas como *Perceptron*, sendo umas das primeiras redes neurais a serem desenvolvidas. São formadas por um agrupamento de neurônios (camada) que recebem simultaneamente os sinais de entrada. A camada única por sua vez liga-se às conexões de saída. É uma rede acíclica que não possui conexões de realimentação como pode ser observado na Figura 28 (REZENDE et al, 2003).

Figura 28 – RNA direta de uma camada.



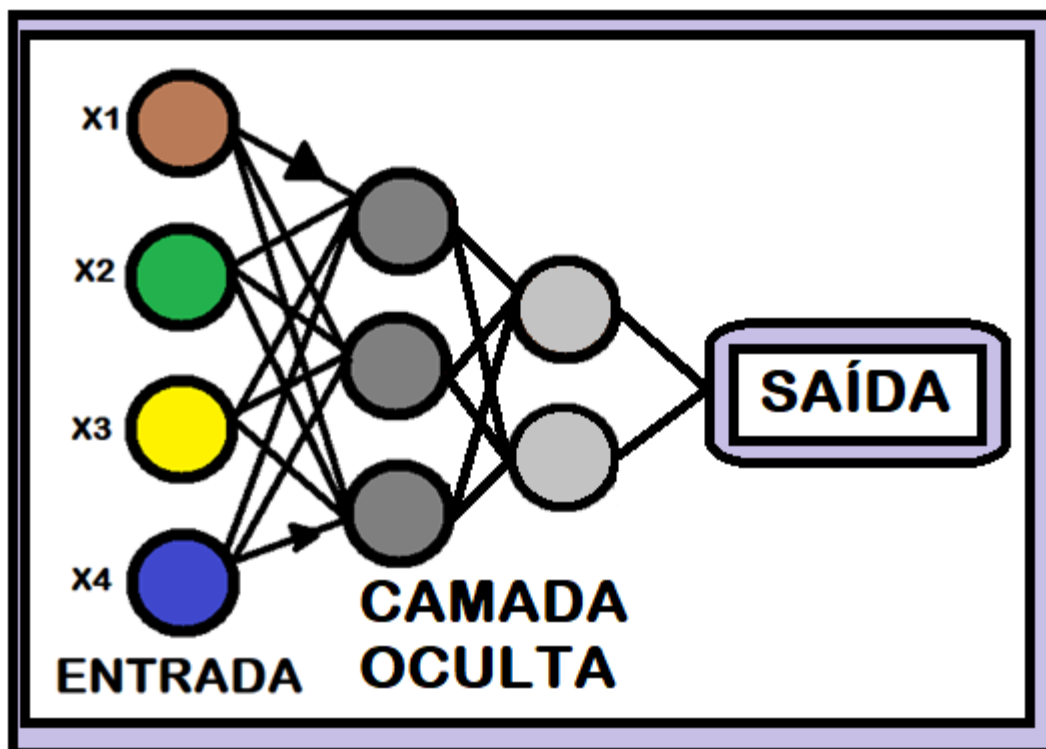
Fonte: O autor (2017).

### 2.6.3.2 Redes Diretas de Multicamadas (*Multilayer Feed Forward Network*)

Diferente da RNA de camada única, esse tipo de rede neural possui uma ou mais camadas ocultas entre a camada de entrada e saída. Possuem fluxo de dados unidirecional e uma grande presença de nós computacionais, devido à existência de neurônios ocultos nas camadas intermediárias. Esse conjunto extra de camadas possibilita um maior número de interações entre neurônios, algo que habilita a rede a extrair características complexas dos sinais de entrada (REZENDE et al, 2003).

Essas redes necessitam de no máximo duas camadas intermediárias, como mostra o exemplo da Figura 29, podendo operar com apenas uma. A camada de saída constrói seu sinal com base no processamento das camadas anteriores, as camadas ocultas são responsáveis por extrair características do sinal codificando-as através de seus pesos sinápticos, tornando o sinal de saída uma representação mais complexa dos padrões inseridos na camada de entrada (REZENDE et al, 2003).

Figura 29 – RNA Direta de Multicamadas.

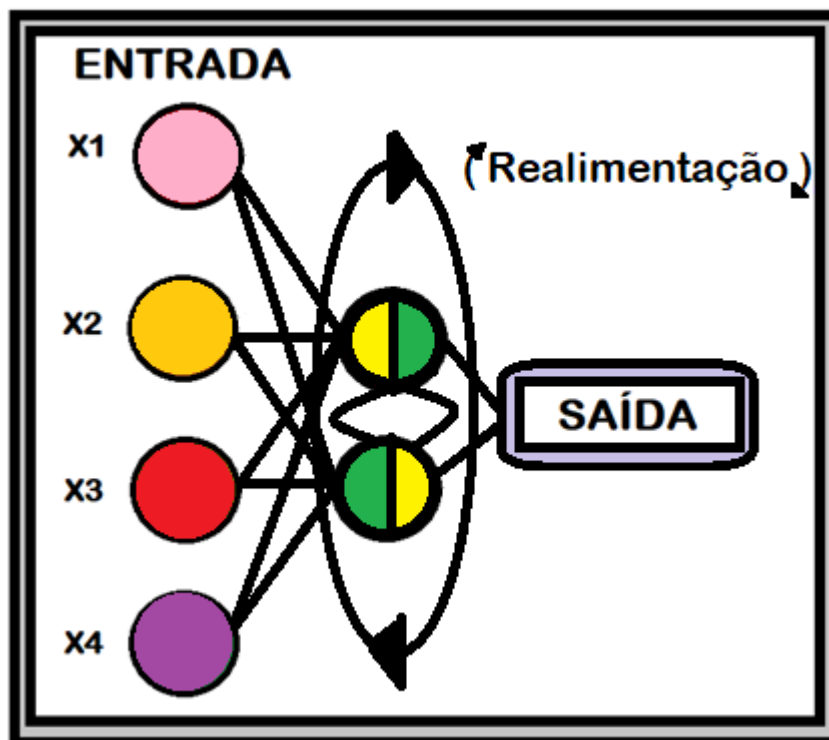


Fonte: O autor (2017).

### 2.6.3.3 Redes Recorrentes (*Feed-Backward*)

São redes neurais onde ocorre realimentação dos sinais de saída, isto é, a saída de uma célula pode ser a entrada de outra pertencente a uma camada anterior, e no caso da auto-realimentação, para a própria célula. RNAs recorrentes possuem no mínimo uma conexão sináptica de realimentação em sua arquitetura (Figura 30), este método resulta em um comportamento mais dinâmico e não-linear (quando a não-linearidade é permitida) por parte da rede, onde as conexões de realimentação utilizam ramos especiais compostos de elementos de atraso unitário (HAYKIN, 2001). Redes Recorrentes são muito utilizadas em séries temporais dinâmicas, filtragem dinâmica e modelos preditivos., técnicas que através de mineração de dados podem oferecer auxílio na predição de informações (KOHONEN, 1988).

Figura 30 – Redes Neurais Recorrentes (Feed Backward).



Fonte: O autor (2017).

Na Tabela 1 são apresentados diferentes tipos de RNAs e suas usuais aplicações, como também limitações e observações pertinentes ao seu funcionamento (MCCORD; ILLINGWORTH, 1990).

Tabela 1 – Comparação entre tipos de RNAs.

<b>Rede</b>	<b>Aplicações</b>	<b>Limitações</b>	<b>Observações</b>
<b><i>Deep Neural Networks</i></b>	Extração de características, mineração de dados, reconhecimento de padrões.	Necessitam de arquitetura profunda e grandes grupos de treinamento.	RNAs profundas são aliadas para resolver problemas complexos (jogos, lógica).
<b><i>Bidirectional Associative Memory (BAM)</i></b>	Endereçamento de conteúdo para memória associativa.	Baixa densidade de armazenamento, os dados devem estar corretamente codificados.	Bom instrumento educacional, une pares fragmentados de objetos a unidades completas.
<b><i>Boltzmann and Cauchy Machines</i></b>	Reconhecimento de exemplos para imagens, sondas e radares.	Boltzmann: tempo longo de aprendizado. Cauchy: Geração de ruídos na estatística de distribuição.	Redes simples utilizada para encontrar o mínimo global.
<b><i>Brain State in a Box</i></b>	Extração de informação de bases de dados.	Estrutura de decisão <i>one-shot</i> – não há raciocínio repetitivo.	Similar a BAM nas saídas fragmentadas e completadas.
<b><i>CNN – Convolutional Neural Network</i></b>	Utilizado no processamento de	Necessita arquitetura profunda.	Alta capacidade em

	imagens.		reconhecimento de imagens e características geométricas.
<b>Multilayer Perceptron</b>	Reconhecimento de Padrões complexos, fala, som.	Raramente exige um número grande de elementos e conexões.	RNA complexa, não é sensível a escalas diferentes (tradução, rotação) hábil a identificar caracteres complexos.
<b>Perceptron</b>	Reconhecimento de caracteres digitados.	Sensível a diferenças de escala (distorções, rotações), não sendo capaz de reconhecer caracteres complexos.	RNA mais conhecida, e mais antiga já criada. Construída inicialmente em hardware é raramente utilizada atualmente.
<b>Self-organizing maps</b>	Traça regiões geométricas, como uma rede elétrica retangular, sobre outro referencial.	Exige aprendizado extensivo.	Um das mais eficientes técnicas para desenvolvimento de mapas inteligentes.

Fonte: (MCCORD; ILLINGWORTH, 1990).

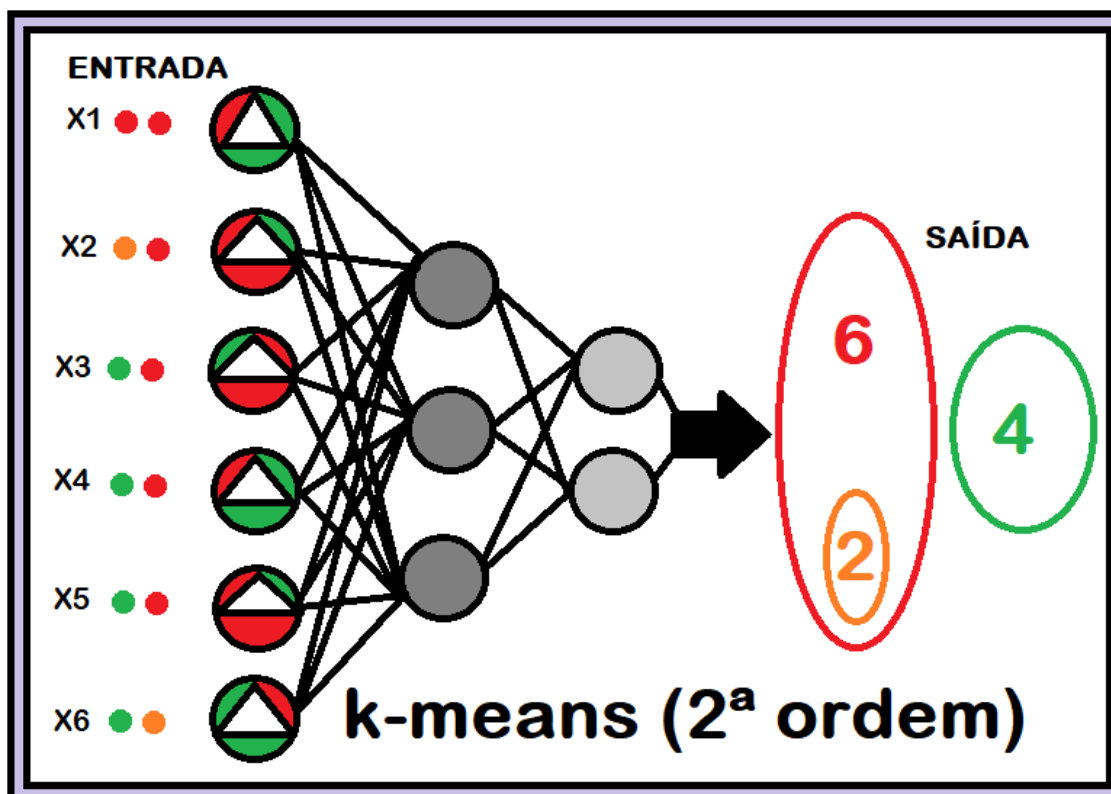
#### 2.6.4 Treinamento de redes neurais: Não Supervisionado e Supervisionado

RNAs usadas no reconhecimento e classificação de padrões geralmente necessitam de treinamento, ou seja, entradas/sinais que sirvam como padrões de referência para que os pesos sinápticos das conexões entre neurônios possam ser estipulados (HAYKIN, 2001). Dois tipos de treinamentos são descritos neste estudo, o treinamento Não Supervisionado e o Supervisionado.

No treinamento Não Supervisionado é necessário que a RNA se auto organize através da extração de padrões significativos dos dados de entrada. Os dados de entrada são a única informação disponibilizada para o treinamento da rede, onde a função de transferência dos neurônios calcula a menor distância Euclidiana entre o vetor de entrada e saída, a célula que possuir a menor distância vence e tem seus pesos atualizados, por esta característica o método também é chamado de Aprendizagem por Competição (HAYKIN, 2001). Alguns dos métodos não supervisionados mais conhecidos pela literatura é o “*k-means*” (média-k), onde além dos sinais de entrada é fornecido uma variável “k” que infere ao algoritmo de aprendizagem o número de padrões a serem encontrados, porém este fato pode mascarar a existência de padrões desconhecidos caso o supervisor não possua conhecimento total sobre a natureza de suas amostras.

Na Figura 31 temos a ilustração de um média-k de 2ª ordem ( $k = 2$ ) classificando um grupo amostral onde na verdade existem 3 padrões de cores distintos (vermelho, laranja e verde). (BOTTOU; BENGIO, 1995).

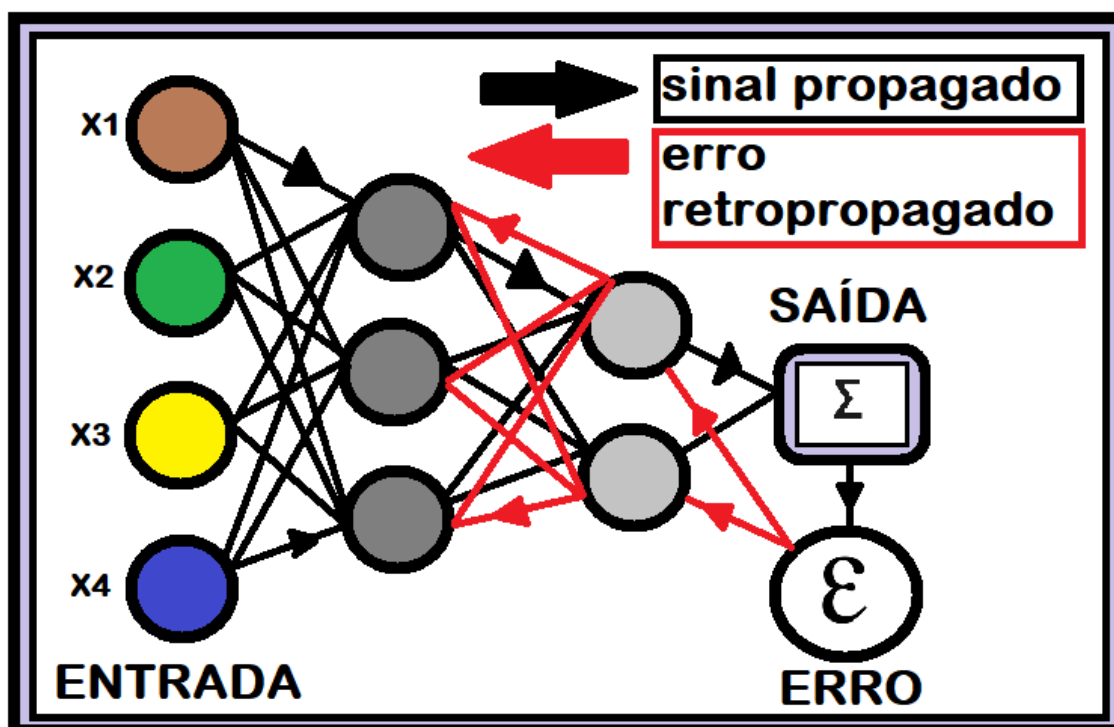
Figura 31 – Diagrama representando um algoritmo de aprendizado Não supervisionado (*K-means*).



Fonte: O autor (2017).

Já no método de aprendizagem supervisionado, o sistema utiliza de uma fonte de feedback extrínseca (supervisor) que por sua vez possui conhecimento em relação a natureza dos dados, o método supervisionado utiliza de informações provenientes do ambiente juntamente com uma resposta esperada (sinal de referência). A RNA supervisionada utiliza como referencial para o ajuste dos pesos sinápticos um sinal de erro gerado pela discrepância entre o sinal esperado (referência) e o sinal real de saída. Cada sinal de entrada/saída utilizado no treinamento gera um sinal erro (custo), simbolizado pela letra epsilon ( $\epsilon$ ) na Figura 32, que é usado para ajustar os pesos sinápticos e minimizar o erro de saída (HAYKIN, 2001).

Figura 32 – Diagrama representando um algoritmo de aprendizado supervisionado, onde o sinal erro  $\epsilon$  é retropropagado pela rede.



Fonte: O autor (2017).

O erro médio quadrático, também conhecido como MSE (erro quadrático médio), é utilizado para avaliarmos a eficiência de uma rede neural (HAYKIN, 2001), e é obtido matematicamente da seguinte maneira;

$$MSE = \frac{1}{N} \sum_{j=1}^M \sum_{k=1}^N (y_{jk} - y_{djk})^2 \quad (28)$$

Onde M é o número de saídas da rede neural, N é o número de amostras de treinamento (referenciais),  $y_j$  é a saída da rede,  $y_{d_j}$  é o valor de saída desejado, e o MSE é o erro médio quadrático entre as saída  $y_j$  e os valores desejados  $y_{d_j}$ . Conforme o aumento do número de amostras de treinamento o valor do MSE diminui convergindo praticamente a um valor constante, que é quando o treinamento da rede é interrompido, devido a estabilização do valor de performance (REZENDE et al, 2003).

Outros métodos também são utilizados para avaliar a performance das RNAs, como o Erro absoluto médio, Entropia cruzada, e a Soma do erro absoluto são outros exemplos. Indiferente dos artifícios matemáticos que a função de performance utiliza o objetivo é o mesmo, auxiliar na avaliação e regulação do desempenho da rede.

Redes bem treinadas são capazes de generalizar problemas, ou seja, não é necessário que a RNA saiba de todas as possibilidades que um sinal de entrada possa apresentar, ou calcular todas as possíveis funções de transferência aplicáveis para



calcular um sinal de saída esperado. Para que a RNA se torne apta a generalizar sua resposta é necessário que a formação de seu banco de dados de treinamento abranja diversas possibilidades e variações em um número restrito de repetições. Um banco de dados diminuto não será o suficiente para que a rede neural generalize problemas com eficiência, enquanto um banco de dados muito extenso eleva pode gerar classificações e respostas indesejadas (*overfitting*) prejudicando a eficiência da rede (REZENDO et al, 2003) (HAYKIN, 2001).

Um dos algoritmos de aprendizagem supervisionada mais amplamente usado e reconhecido pela literatura é o algoritmo de Retropropagação (*Backpropagation*) (HECHT, 1998). Suas aplicações e características serão apresentadas a seguir.

#### 2.6.5 Algoritmo de Retropropagação (*Backpropagation*)

O algoritmo de retropropagação é utilizado em redes neurais de multicamadas (*Multilayer perceptron*) utilizando funções de transferência sigmóide. O processo completo pode ser descrito em duas etapas, *forward* e *backward*. No primeiro passo (*forward*), um sinal é apresentado a camada de entrada da RNA que subsequentemente se propaga pelas camadas intermediárias até a saída do sistema, sem alterar o valor dos pesos sinápticos das conexões entre os neurônios. No momento seguinte (*backward*) o sinal é comparado com a saída desejada e o erro (custo) é calculado, a seguir o erro é retropropagado pelo sistema reajustando os pesos sinápticos até a camada de entrada da rede neural, de forma a minimizar o custo (BRAGA et al, 2000).

Esse treinamento deve ocorrer múltiplas vezes para cada tipo de padrão escolhido como referência, um ciclo completo deste processo é chamado de época (*epoch*). O treinamento só é terminado quando o erro de saída alcança valores abaixo de um limite estipulado, sendo várias épocas necessárias para que a rede obtenha resultados positivos na classificação de padrões (BRAGA et al, 2000).

A técnica de retropropagação abrange uma família de algoritmos que utiliza da Regra Delta, porém aplicada em múltiplos níveis. A regra delta é um conjunto de instruções que procura obter um ponto mínimo através de iteração local. Utilizando exemplos do conjunto de treinamento parte-se de um ponto arbitrário e no sentido que o algoritmo evolua o ponto de partida no sentido oposto do gradiente naquele ponto. A resposta desejada é utilizada como parâmetro de supervisão e o erro correspondente é usado para atualizar os pesos sinápticos em cada iteração. O passo adotado pela RNA na busca pelo ponto mínimo global é representado pela taxa de aprendizado, uma constante positiva que varia seu valor entre 0 e 1 (HECHT, 1989) (BRAGA et al, 2000).

A diferença mais característica entre a regra delta e a retropropagação está na superfície de erro dos algoritmos. Enquanto a regra delta possui uma superfície côncava, ou seja, um ponto mínimo local é o mínimo global da superfície, algoritmos de retropropagação possuem múltiplos pontos mínimos locais, fazendo com que o algoritmo possa ficar preso em um ponto mínimo local, não convergindo para o real mínimo global (HECHT, 1989).

A formulação matemática da técnica de retropropagação é apresentada no APÊNDICE A.

O esforço computacional dos algoritmos de retropropagação é considerado razoável, devido ao fato de que geralmente apenas o vetor gradiente é armazenado durante o aprendizado. Algoritmos dessa classe podem ser referenciados: *Scaled conjugate gradient backpropagation* (SCG); *Resilient backpropagation* (RPROP); *Quasi-Newton backpropagation* (BFGS). São todos exemplos de uma das melhores famílias de algoritmos implementados para aprendizagem supervisionada em aprendizado de máquina (RIEDMILLER; BRAUN, 1993).


### **3 MATERIAIS E MÉTODOS**

#### **3.1 SISTEMA DE AQUISIÇÃO**

A placa de aquisição foi desenvolvida com o intuito de ser fixada em um ponto específico do shape do skate. A definição desse ponto foi adotada com base nos estudos realizados anteriormente (ANLAUFF et al, 2010) (GROH et al, 2015), onde o sensor inercial foi posicionado próximo ao eixo anterior do skate.

A placa de aquisição consiste de 5 componentes como podemos observar no diagrama da Figura 33. Os componentes possuem as seguintes propriedades e características;

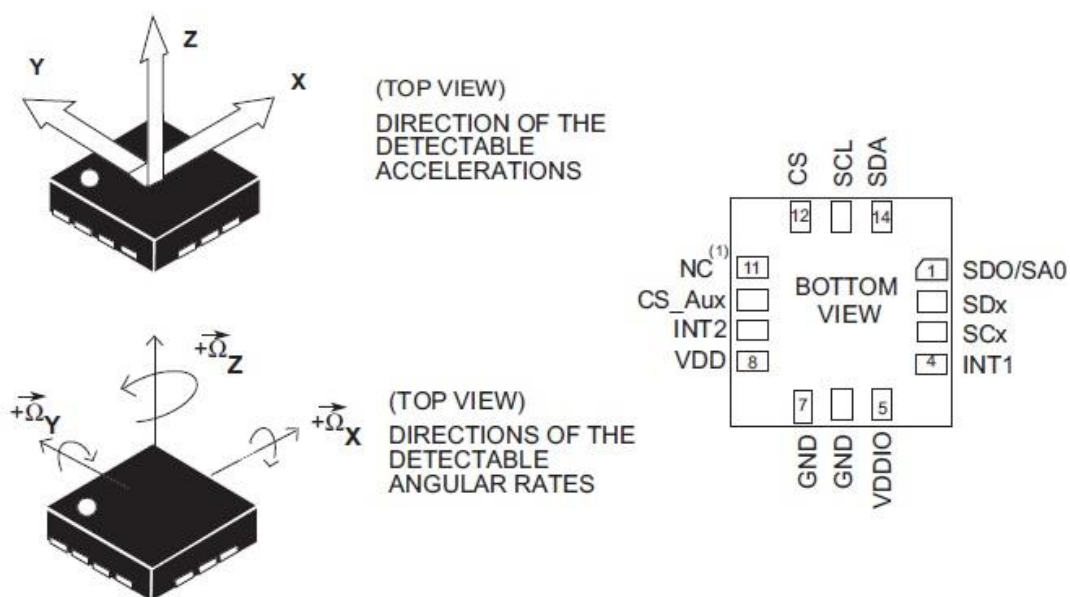
Figura 33 – Diagrama dos componentes da placa de aquisição.



Fonte: O autor (2017).

- Bateria: fora utilizada uma bateria LIPO de 3,7 V com capacidade de corrente de 1000 mA/h, aliada a um regulador de tensão responsável por compatibilizar a tensão da bateria com a tensão de operação dos demais componentes (3,3 V).
- Sensor (Acelerômetro/Giroscópio): o sensor utilizado é o IMU LSM6DS3H (Figura 34), com acelerômetro e giroscópio 3D. O sensor possui um consumo de energia de 1,1 mA e opera com valores de tensão entre 1,7 ~ 3,6 V. Ambos acelerômetro e giroscópio possuem uma taxa de amostragem ajustável, de até 6,660 amostras/s para o acelerômetro e de até 3,330 amostras/s para o giroscópio. O acelerômetro possui uma escala ajustável de  $\pm 2$  g até  $\pm 16$  g, enquanto o giroscópio possui uma escala ajustável de até  $\pm 2000^\circ$ /s. O sensor opera entre temperaturas de  $-40$  e  $85$  C°. A sensibilidade do acelerômetro a 16 g é de 0,488 mg/LSB, e para o giroscópio na mesma faixa de medição a sensibilidade é de 70 mdps/LSB. Em modo de alta performance o ruído total (escala:  $\pm 16$  g) é de 4,4 mgRMS (STMICROELECTRONICS, 2016). Este dispositivo possui portas de comunicação SPI e I<sup>2</sup>C. No projeto foi determinado que a porta de comunicação com o microcontrolador seria feita por I<sup>2</sup>C, uma vez que este protocolo tem mecanismo de *handshake* o que aumenta a confiabilidade da comunicação.

Figura 34 – Esquema de alinhamento dos eixos do sensor inercial LSM6DS3H .



Fonte: (STMICROELECTRONICS, 2016).

- Microcontrolador: o microcontrolador utilizado foi o MSP430F2274, com processamento de 16 bits. Este microcontrolador possui duas portas completas UCSI (UART, SPI, I<sup>2</sup>C e IrDA), dois temporizadores de 16 bits, um conversor A/D de 10 bits, multiplicador de hardware, DMA, e um encapsulamento QFN de 32 pinos para construção de um dispositivo com pequenas dimensões. O microcontrolador opera entre 1,8 ~ 3,6V com um consumo de energia de 195  $\mu$ A/MHz em 3,3 V.
- Rádio: os sinais são transmitidos para a estação de controle (*notebook/smartphone*) por meio de um rádio ODIN-W2. Esse componente opera entre 3,0 ~ 3,6 V com um consumo de energia de até 130 mA, quando transmitindo dados consumo é em média de 110 mA. ODIN-W2 possui um alcance de até 250 m com uma taxa de transferência de até 20 Mbps utilizando Wi-fi, e 1,3 Mbps utilizando bluetooth.


O sistema proposto opera similarmente a versões comerciais já existentes, como o STEVAL-WESU1 (Figura 35), desenvolvido pela STMICROELECTRONICS para aplicações relacionadas à detecção de movimentos utilizando o mesmo sensor inercial proposto, IMU LSM6DS3, com uma configuração de componentes similar (sensor, micro controlador, rádio) (Figura 36) .

Figura 35 – Relógio STEVAL-WESU1



Fonte: (STMICROELECTRONICS, 2017).

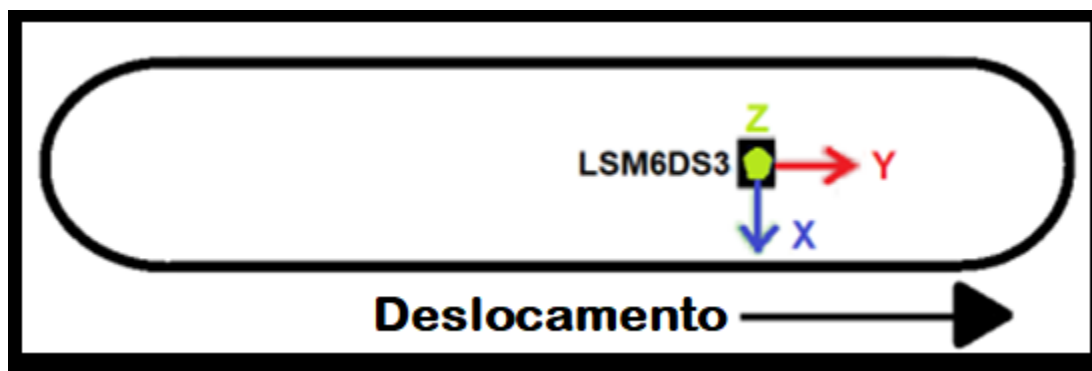
Figura 36 – Sensor LSM6DS3 do Sistema STEVAL-WESU1.



Fonte: (STMICROELECTRONICS, 2017).

O sensor proposto (LSM6DS3) possui uma escala de até 16 g, a mesma escala utilizada no estudo de Groh e colaboradores (2015). A orientação dos eixos do sensor pode ser visualizada na Figura 37.

Figura 37 – Orientação dos eixos do sensor LSM6DS3.



Fonte: O autor (2017).

### 3.2 AMOSTRAS

Para gerarmos os sinais de aceleração que representam os eventos de interesse foi utilizado como referência os padrões de aceleração documentados por Groh e colaboradores (2015) em seu estudo. Na Tabela 2 vemos a comparação de deslocamento de cinco classes de manobras pelo plano cartesiano X, Y, Z, e a orientação das bases regular e goofy.

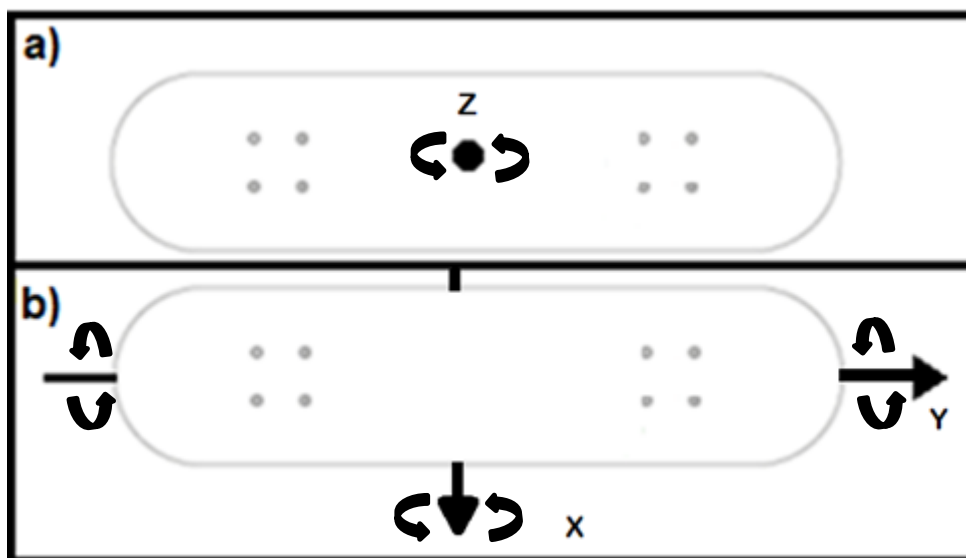
Tabela 2 – Glossário de classes e suas respectivas movimentações

Classe	Definição	Difere nos eixos: (regular / goofy)
<b>Regular</b>	pé dianteiro: esquerdo pé traseiro: direito	-
<b>Goofy</b>	pé dianteiro: direito pé traseiro: esquerdo	-
<b>Ollie</b>	nose: ascende, tail: ascende principal rotação: eixo-X	eixo-X (+X, -X)
<b>Nollie</b>	tail: ascende, nose: ascende principal rotação: eixo-X	eixo-X (-X, +X)
<b>Kickflip</b>	nose: ascende, tail: ascende principal rotação: eixo-Y	eixo-Y
<b>Nollie Backside Shove it</b>	tail: ascende, nose: ascende principal rotação: eixo-Z	eixo-Z eixo-Y
<b>Backside Shove it</b>	nose: ascende, tail: ascende principal rotação: eixo-Z	eixo-Z eixo-Y

Fonte: (GROH et al, 2015) adaptado pelo autor (2017).

Para melhor compreensão das rotações realizadas pelas manobras citadas, a Figura 38 ilustra estas movimentações.

Figura 38 – Orientação da rotação do skate com base nos eixos do Z (a), X e Y (b).



Fonte: O autor (2017).

Manobras similares, de um ponto de vista totalmente unidimensional, são aquelas onde a aceleração do skate pelo espaço possui uma assinatura semelhante em um ou mais eixos. No caso da classe Kickflip (rotação no eixo X e Y) e classe Ollie (rotação no eixo X), ambos se diferenciam pela rotação de  $360^\circ$  do skate no eixo Y que o Kickflip possui. Já a classe Nollie Backside Shove it tem uma rotação de  $180^\circ$  em torno do eixo Z similar a classe Shove it, porém Nollie Backside Shove it tem a elevação do tail antes do nose, ao contrário da classe Shove it. Ambas as classes Nollie e Nollie Backside Shove it são executadas com a mesma base, posição dos pés (Nollie), e ambas tem em comum a elevação do tail antes da elevação do nose. Para que sinais de aceleração possam ser gerados artificialmente é necessário que esses apresentem similaridades e discrepâncias próximas ao fenômeno natural.


Foram utilizadas as cinco classes de manobras explanadas na Tabela 2 para o desenvolvimento dos classificadores. Ao todo foram gerados 543 sinais de aceleração (X, Y, Z), resultando em 181 manobras com uma distribuição aleatória entre 50 e 30 amostras por classe, 32 Nollie (NOLLIE), 42 Nollie Backside Shove it (NSHOV), 37 Kickflip (FLIP), 32 Backside Shov it (SHOV), e 38 Ollie (OLLIE). Para as classes OLLIE, NOLLIE e SHOVS foi usado a base regular como referência da movimentação do skate, e para as classes NSHOV e FLIP a base goofy. Essa medida foi adotada para testar a interferência da base do indivíduo durante o processo de classificação.

### 3.3 GERAÇÃO DOS SINAIS E JANELAMENTO

Os sinais de aceleração foram gerados utilizando o software MATLAB 2015 e o *Signal Processing Toolbox*. Inicialmente os sinais foram elaborados a partir de um

signal de base, esse sinal foi utilizado como referência do eixo Y (mg) para os três eixos. O eixo-Z, por medir o componente gravitacional do sistema, teve sua linha de base ajustada para a marca de - 1.000 mg, na Figura 39 vemos o sinal de base.


Figura 39 – Sinal de Base.



Fonte: O autor (2017).

Através da interpolação de triângulos com base e altura determinadas por uma distribuição gaussiana (dentro de um limite inferido pela inspeção dos sinais referência), foram modelados representações geométricas do fenômeno real, como mostra a Figura 40. Calculando a média móvel (MA de 2ª ordem) das representações geométricas obtemos um sinal modelo compatível com as referências utilizadas. A variação dos valores de base e altura dos triângulos, com acréscimo de ruído gaussiano, permitiu a geração de diferentes sinais com uma aparência similar ao fenômeno real (GROH et al, 2015).

Figura 40 – Modelagem do sinal artificial.




Fonte: O autor (2017).



Na Figura 41 mostramos uma amostra real (Nollie) comparada com duas amostras artificiais.


Figura 41 – Comparação entre o Nollie referência e o sinal artificial .



Fonte: a) O autor (2017).

O método utilizado se provou eficiente em gerar uma assinatura similar a encontrada na literatura (GROH et al, 2015). Este processo foi realizado pra cada classe de manobra e suas três assinaturas (X,Y e Z), os sinais referência criados foram acrescidos com ruído gaussiano, para adicionar o usual ruído captado durante a aquisição de fenômenos físicos. Assim for gerados um total de 543 sinais, 181 eixo-X, 181 eixo-Y, 181 eixo-Z. Na Figura 42 vemos o sinal artificial com o ruído gaussiano acrescentado. O código (C) utilizado para gerar os sinais utilizados é exposto no Apêndice B.

Figura 42 – SHOV gerado artificialmente com ruído gaussiano acrescentado.




Fonte: O autor (2017).

O correto janelamento foi alcançado utilizando técnicas similares as encontradas na literatura (ANLAUFF et al, 2010) (GROH et al, 2015), buscando pelos picos máximos que caracterizam cada eixo. Perturbações acima de 5,000 mg em relação a linha de base correspondem ao início de um evento de interesse, já

perturbações acima de 10,000 mg correspondem a ápices de aceleração dos eventos. Na Figura 42 vemos como esses picos se diferenciam de demais perturbações e ruídos.

Foi estipulado que com no máximo 90 pontos, amostrados em 50 amostras/s (tempo enlapsado  $\approx$  1 segundo) , seria o suficiente janelar qualquer manobra realizada no solo, utilizando como marcadores para a contagem dos pontos os picos máximos de aceleração de cada eixo. Quando analisamos separadamente os três eixos de cada classe observamos assinaturas distintas, essas causadas pelas diferentes movimentações que compõem cada classe em seus três componentes, X, Y e Z (Figura 43).

Figura 43 – Assinatura das classes entre os eixos de aceleração X, Y, Z..



Fonte: O autor (2017).

As similaridades e diferenças entre os sinais gerados foram quantizadas utilizando a correlação cruzada entre os sinais.

### 3.4 HEURÍSTICA DE CLASSIFICAÇÃO

Primeiramente, para que fosse desenvolvido uma heurística de classificação, foram utilizados 84 sinais (28 sinais do eixo-X, 28 sinais do eixo-Y, 28 sinais do eixo-Z), equivalente a sete manobras divididas entre quatro classes (FLIP, OLLIE, NSHOV e SHOV). A classe NOLLIE não foi utilizada nessa etapa com o intuito de simplificar o problema, dado a semelhança entre as classes OLLIE e NOLLIE (GROH et al, 2015).

Para que os 84 sinais pudessem ser classificados foi necessário definir quais características melhor representavam cada classe. Foram escolhidos como Alvos (referências) os sinais mais representativos de cada classe (FLIP, OLLIE, NSHOV, SHOVS). Como cada Alvo necessita de três referenciais distintos (X, Y e Z), o padrão mais representativo de cada eixo (Alvo-X, Alvo-Y e Alvo-Z) foi calculado para cada classe.

A definição dos alvos foi realizada utilizando a correlação cruzada (Xcorr) entre todas as amostras pertencentes ao mesmo eixo e classe (FLIP1X, FLIP2X...FLIP7X). A correlação cruzada é uma medida de semelhança entre dois sinais em função de um atraso aplicado (lag). Esta função é utilizada no processamento de sinais para detecção de sinais curtos dentro de sinais mais longos e no reconhecimento de padrões.

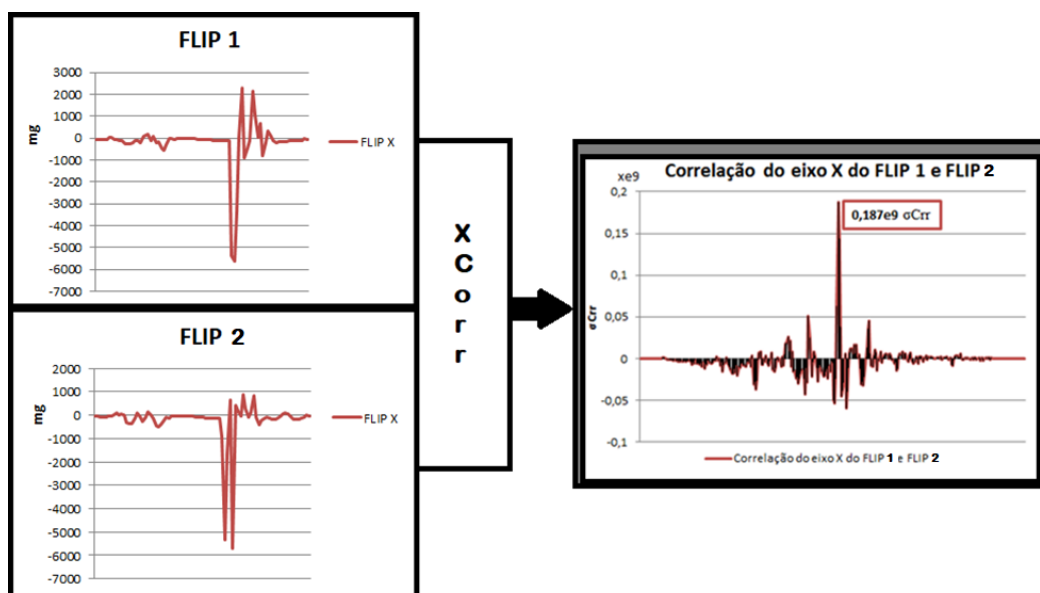
Todos os sinais processados são eventos discretos, assim, a correlação cruzada de duas funções discretas é definida pela Equação 28:

$$(f * g)[n] \stackrel{\text{def}}{=} \sum_{m=-\infty}^{\infty} f[m]g[m+n] \quad (28)$$

Similar a convolução de duas funções a correlação cruzada contudo possui algumas características que a diferem, pois na correlação cruzada não ocorre o espelhamento de um dos sinais, e diferente da convolução a correlação cruzada não é comutativa.

A correlação cruzada entre sinais resulta em outro sinal, onde o pico máximo ( $\sigma_{Crr}$ ) de cada correlação cruzada foram registrados, como ilustra a Figura 44.


Figura 44 – Correlação cruzada entre o FLIP 1 e o FLIP 2, eixo X.



Fonte: O autor (2017).

Foi claculada a correlação cruzada de cada permutação possível, como demonstra a Figura 45, utilizando como exemplo os sinais do eixo X de todos os 7 sinais (FLIP X) utilizados. Este processo foi realizado para cada um dos eixos de todas as quatro classes.

Figura 45 – Correlação cruzada entre todos os sinais do eixo X de FLIP.



Fonte: O autor (2017).

O pico máximo de cada possível correlação cruzada entre sinais do mesmo eixo/manobra foram somados e divididos pelo número de permutações possíveis, seis, pois a autocorrelação não foi adicionada na obtenção do valor médio. Assim foi possível obter o sinal com o maior valor em  $\sigma_{Crr}$ , ou seja, o sinal que melhor representava seu conjunto (Alvo). A Tabela 3 demonstra quais sinais atingiram valores mais altos de correlação quando comparadas com outros sinais pertencentes ao mesmo grupo.

Tabela 3 – Alvos

	ALVO FLIP	ALVO OLLIE	ALVO NSHOV	ALVO SHOV
X	FLIP 5	OLLIE 3	NSHOV 6	SHOV 5
Y	FLIP 7	OLLIE 1	NSHOV 7	SHOV 1
Z	FLIP 5	OLLIE 5	NSHOV 1	SHOV 5

Fonte: O autor (2017).

Na seção de RESULTADOS descrevemos as diferenças e similaridades encontradas nos sinais que formam cada classe, como também os métodos utilizados para diferenciar as classes avaliadas.

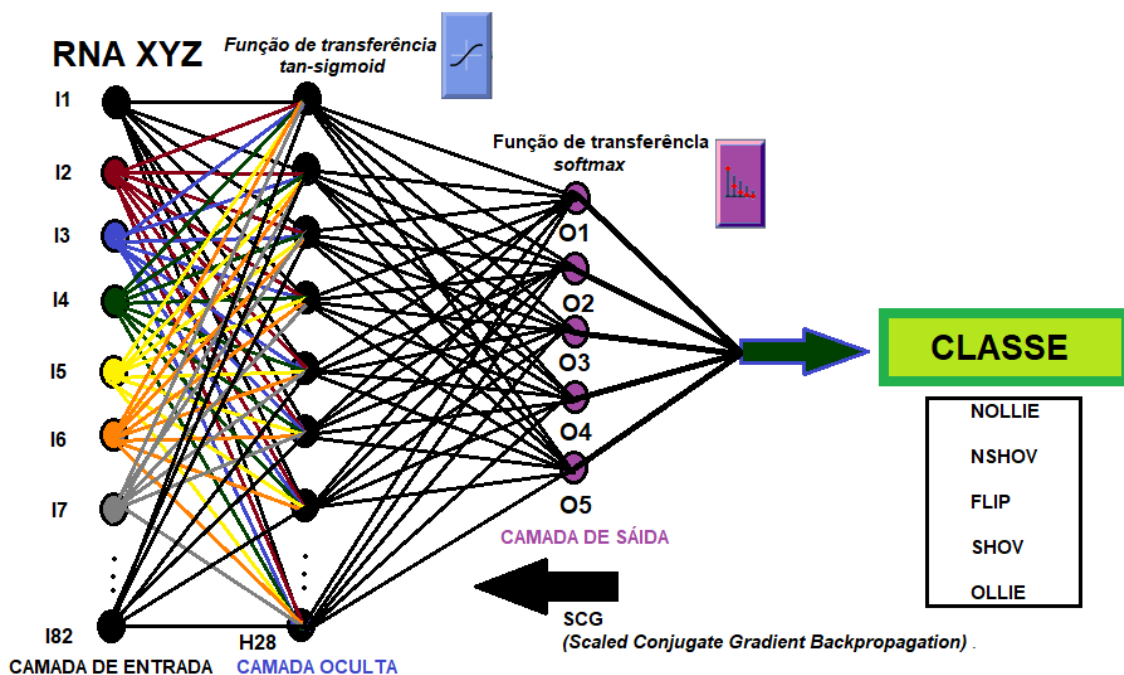
### 3.5 ARQUITEURA DA RNA

Foi utilizada a ferramenta de reconhecimento de padrões da *Neural Network Toolbox* (nnstart) (nprtool), disponível no software MATLAB 2015.

Foram treinadas RNAs utilizando todos os sinais (RNA XYZ) e RNAs treinadas em eixos específicos (RNA X, RNA Y, RNA Z). Para a RNA XYZ foram utilizados 367 amostras (80%) para o treinamento, 46 amostras (10%) para a validação, e 46 amostras (10%) para testar e medir a performance da rede. Já as RNAs treinadas em eixos específicos receberam 153 (80%) amostras para treinamento, 15 amostras (10%) para validação, e 15 amostras (10%) para o teste de performance. A performance das redes treinadas foi medida através do método de Entropia cruzada.

A arquitetura da RNA desenvolvida possui três camadas, formada por uma camada de entrada composta por 82 neurônios (tamanho do sinal de entrada), uma camada oculta com 28 neurônios e uma camada de saída com 5 neurônios, que correspondem as cinco classes. O diagrama da Figura 46 ilustra a RNA arquitetada.

Figura 46 – Arquitetura da Rede Neural Artificial



Fonte: O autor (2017).

A definição do número de camadas e o número de neurônios são características importantes a serem consideradas, devido a problemas de convergência (base de dados pequena) e *overfitting*. A Equação 29 propõem uma métrica para a definição desses parâmetros com intuito de aprimorar a arquitetura da RNA (HECHT, 1989).

$$N_e \leq \frac{N \times \varepsilon_{train}}{N_{in} + N_{out}} \quad (29)$$

Onde  $N_e$  é o número de neurônios na camada escondida,  $N$  é o Número de padrões,  $\varepsilon_{train}$  o erro permitido (tolerância),  $N_{in}$  o número de entradas e  $N_{out}$  o número de neurônios na camada de saída. Também se recomenda que o número de neurônios na camada escondida nunca seja maior que duas vezes o número de neurônios na camada de entrada da RNA.

Por fim, a RNA arquitetada é uma *Multilayer Feed Forward Network* com uma função de transferência tan-sigmoide na camada oculta e uma função de transferência *softmax* na camada de saída. Como algoritmo de aprendizagem foi utilizado o SCG.


## 4 RESULTADOS E DISCUSSÃO

Nesta seção são expostos e discutidos os resultados adquiridos durante a classificação dos sinais. A discriminação entre sinais foi alcançada através do método de correlação cruzada e pelas RNAs treinadas.

### 4.1 RANKING DE RELEVÂNCIA DOS EIXOS X, Y, Z ENTRE OS ALVOS.


As Tabelas 4, 5, 6 e 7 ilustram a comparação (correlação cruzada) de 84 sinais contra cada Alvo construído e relatado na Tabela 3. Os resultados são a média aritmética dos picos de correlação ( $\sigma_{Crr}$ ) de cada comparação. O eixo com maior relevância (peso) na tarefa de diferenciar cada classe (Alvo) das demais foi simbolizado com dois asteriscos (\*\*), enquanto o eixo com relevância intermediária foi utilizado com um asterisco (\*), e o eixo com menor relevância não possui marcação. A linha circulada em azul corresponde aos resultados do Alvo quando pontuando a sua própria classe.

Tabela 4 – Média de correlação para o Alvo OLLIE.




Fonte: O autor (2017).

Tabela 5 – Média de correlação para o Alvo FLIP.




Fonte: O autor (2017).

Tabela 6 – Média de correlação para o Alvo NSHOV.



Fonte: O autor (2017).

Tabela 7 – Média de correlação para o Alvo SHOV.



Fonte: O autor (2017).

Através destes resultados foi possível desenvolver métodos que utilizassem estes valores de correlação cruzada para pontuar às avaliações de cada Alvo em relação aos sinais de entrada. Também vemos pela análise das Tabelas 4 – 7 quais classes (e seus respectivos eixos) são mais prováveis a serem classificadas falsamente, sendo o eixo-Z o eixo que obtém os maiores valores em correlação quando comparado com os demais (X, Y). Essa relação entre os eixos foi utilizada para otimizar a performance das RNAs.

#### 4.2 CLASSIFICAÇÃO POR XCORR E COEFICIENTES DE CORRELAÇÃO.

Os sinais referência de cada Alvo (x) junto com os sinais de entrada provenientes de cada manobra detectada (y) foram rankiados pela AutoSoma (Equação 30) e a AutoCorrelação (Equação 31):

$$AutoSoma = (xy\sigma CrrX + xy\sigma CrrY + xy\sigma CrrZ) \quad EQ (30);$$

$$AutoCorrelação = (xy\sigma CrrX)^2 + (xy\sigma CrrY)^2 + (xy\sigma CrrZ)^2 \quad EQ(31).$$

Onde  $\sigma CrrX$ ,  $\sigma CrrY$  e  $\sigma CrrZ$  representam os picos de correlação cruzada entre os sinais do alvo (x) e os sinais de entrada (y), em respeito aos eixos de aceleração avaliados (X, Y, Z).

Essa avaliação foi feita utilizando todos os eixos, ou apenas os mais relevantes:

$$AutoSoma0 = (xy\sigma CrrX + xy\sigma CrrZ) \quad EQ(32);$$

$$AutoCorrelação0 = (xy\sigma CrrX)^2 + (xy\sigma CrrZ)^2 \quad EQ(33);$$




$$\text{AutoSoma00} = xy\sigma\text{CrrZ} \quad \text{EQ(34);}$$

$$\text{AutoCorrelação00} = (xy\sigma\text{CrrZ})^2 \quad \text{EQ(35);}$$


As Tabelas 8, 9, 10 e 11 mostram os resultados e pontuações de cada Alvo utilizando os métodos descritos para pontuar 84 sinais de entrada entre quatro classes. Os métodos que obtiveram a melhor diferenciação entre a classe do Alvo e as demais foram circutados em azul.

Tabela 8 – Alvo OLLIE, comparação entre o método de AutoSoma e AutoCorrelação.




Fonte: O autor (2017).

Tabela 9 – Alvo FLIP, comparação entre o método de AutoSoma e AutoCorrelação.




Fonte: O autor (2017).

Tabela 10 – Alvo NSHOV, comparação entre o método de AutoSoma e AutoCorrelação.



Fonte: O autor (2017).

Tabela 11 – Alvo SHOV, comparação entre o método de AutoSoma e AutoCorrelação.



Fonte: O autor (2017).

Os resultados indicam que a comparação da auto correlação pelo produto cruzado descartando a avaliação do eixo menos significativo (AutoCorrelação0) é o método onde os sinais possuem mais chance de serem corretamente classificados pelos Alvos. Contudo, vemos que com apenas a interpretação do eixo-Z, estatisticamente o Alvo com maior pontuação continua sendo o correto. Na Tabela 12 vemos uma matriz de confusão onde são apresentados a média dos coeficientes de correlação entre os sinais pertencentes ao eixo-Z. Em verde vemos o valor da correlação entre a classe com siglo mesma, em vermelho a classe menos correlacionada, e em azul as classes com maior probabilidade de serem classificadas incorretamente.

Tabela 12 – Matriz de confusão dos coeficientes de correlação entre as cinco classes (eixo-Z).

CLASSE	Coeficiente de Correlação					
1	NOLLIE	0.875	0.781	0.642	0.433	0.732
2	NSHOV	0.781	0.824	0.630	0.567	0.496
3	FLIP	0.642	0.630	0.704	0.384	0.657
4	SHOV	0.433	0.567	0.384	0.633	0.164
5	OLLIE	0.732	0.496	0.657	0.164	0.861
		NOLLIE	NSHOV	FLIP	SHOV	OLLIE
		1	2	3	4	5

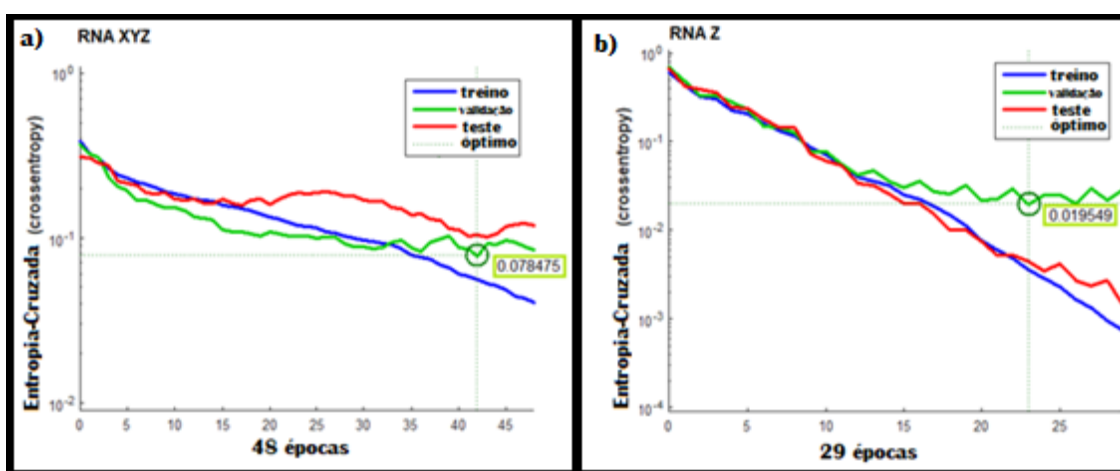
Fonte: O autor (2017).

### 4.3 CLASSIFICAÇÃO POR RNA.

A seguir serão apresentados os dados de desempenho das RNAs treinadas neste estudo utilizando a configuração (arquitetura/cota de treinamento/funções de transferência/ algoritmo de aprendizagem) apresentada anteriormente.

Na Figura 47 vemos a diminuição dos valores de entropia cruzada (valores baixos significam boa classificação) durante o treinamento e validação da RNA XYZ (a) e da RNA Z (b). Percebe-se que a validação da RNA XYZ obteve o melhor resultado em sua performance (valor mínimo de entropia cruzada) na iteração (época) número 42, com o resultado de performance de 0,078475, enquanto na iteração 48 o aprimoramento na capacidade de generalização da rede cessou. Já os valores de performance foram aprimorados nas RNAs treinadas em apenas um eixo, como no caso da RNA Z, com valor mínimo de entropia cruzada de 0,019549 na 23ª iteração.

Figura 47 – Performance da RNA XYZ e RNA Z, Performance (Entropia-Cruzada) x número de iterações (épocas).



Fonte: O autor (2017).

Na Tabela 13 vemos a matriz de confusão da RNA XYZ, onde o percentual total de manobras classificadas corretamente e incorretamente durante os estágios de treinamento e validação pode ser visualizado. As classe seguem a seguinte legenda: NOLLIE (NO), NSHOV (NS), FLIP (F), SHO V (S), OLLIE (O).

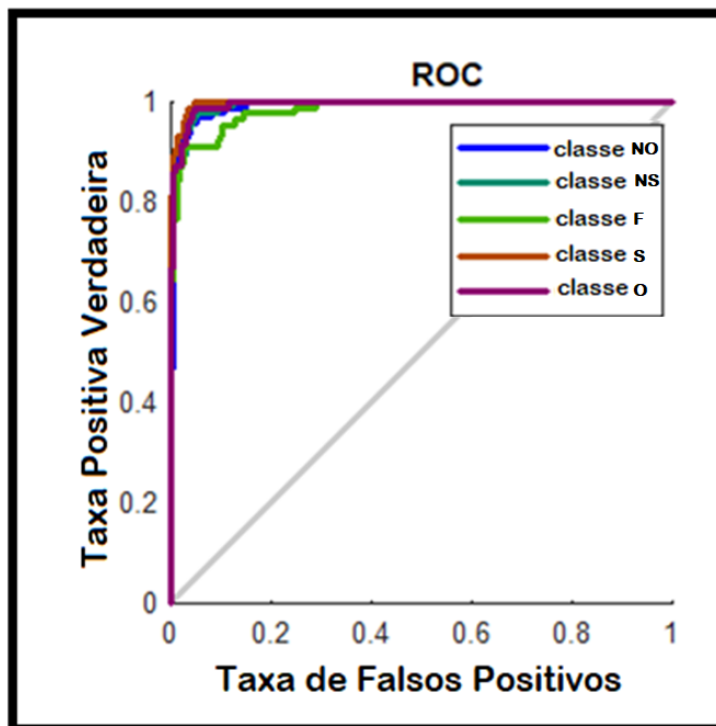
Tabela 13 – Matriz de confusão da RNA XYZ.

<b>Sinal Classificado</b>	<b>NO</b>	90 19.6%	3 0.7%	4 0.9%	1 0.2%	1 0.2%	90.9% 9.1%
	<b>NS</b>	3 0.7%	98 21.4%	3 0.7%	4 0.9%	0 0.0%	90.7% 9.3%
	<b>F</b>	0 0.0%	0 0.0%	78 17.0%	0 0.0%	7 1.5%	91.8% 8.2%
	<b>S</b>	2 0.4%	4 0.9%	1 0.2%	70 15.3%	1 0.2%	89.7% 10.3%
	<b>O</b>	1 0.2%	0 0.0%	4 0.9%	0 0.0%	84 18.3%	94.4% 5.6%
			93.8% 6.3%	93.3% 6.7%	86.7% 13.3%	93.3% 6.7%	90.3% 9.7%
		<b>NO</b>	<b>NS</b>	<b>F</b>	<b>S</b>	<b>O</b>	
		<b>Classe Alvo</b>					

Fonte: O autor (2017).

A RNA XYZ obteve um percentual de acerto de 91,5% (erro = 8,5%), Na Figura 48 o *Receiver Operating Characteristic* (ROC) do treinamento e validação da rede mostra o percentual de predições corretas como uma função de quantas predições incorretas estamos dispostos a tolerar. O quanto mais distante as linhas correspondentes as classes estiverem do canto inferior direito do gráfico, melhor o resultado do classificador.

Figura 48 – Receiver Operating Characteristic do treinamento e validação da RNA XYZ.



Fonte: O autor (2017).

A disposição das linhas (classes) no gráfico ROC e o percentual de acerto de na matriz de confusão caracterizam a RNA como um classificador apto a diferenciar entre até 5 tipos diferentes de classes com um percentual de erro de 8,5%. Contudo o classificador RNA XYZ possui três padrões distintos (sinais X, Y e Z) para associar a cada classe, quando testamos a mesma rede (RNA XYZ) utilizando sinais correspondentes a um único eixo obtivemos resultados melhores, onde a classificação dos sinais correspondentes aos eixos X, Y e Z obteve os respectivos resultado, 88,2% (erro = 11,8%), 89,5% (erro = 10,5%) e 96,1% (erro = 3,9%).


Já na matriz de confusão da Tabela 14 mostramos o percentual de acerto da RNA Z classificando apenas amostras provenientes do eixo Z, o que resultou em um percentual de acerto de 98,7% (erro = 1,3%), e na Figura 52 o ROC de classificação da RNA Z.

Tabela 14 – Matriz de confusão da RNA Z.

<b>Sinal Classificado</b>	<b>NO</b>	31 20.3%	1 0.7%	0 0.0%	0 0.0%	0 0.0%	96.9% 3.1%
	<b>NS</b>	1 0.7%	34 22.2%	0 0.0%	0 0.0%	0 0.0%	97.1% 2.9%
	<b>F</b>	0 0.0%	0 0.0%	30 19.6%	0 0.0%	0 0.0%	100% 0.0%
	<b>S</b>	0 0.0%	0 0.0%	0 0.0%	25 16.3%	0 0.0%	100% 0.0%
	<b>O</b>	0 0.0%	0 0.0%	0 0.0%	0 0.0%	31 20.3%	100% 0.0%
			96.9% 3.1%	97.1% 2.9%	100% 0.0%	100% 0.0%	100% 0.0%
		<b>NO</b>	<b>NS</b>	<b>F</b>	<b>S</b>	<b>O</b>	
		<b>Classe Alvo</b>					

Fonte: O autor (2017).

Figura 49 – Receiver Operating Characteristic na classificação dos sinais do eixo Z.



Fonte: O autor (2017).

Os resultados das demais RNAs treinadas na classificação de eixos específicos, X e Y, obtiveram os respectivos percentuais de acerto, 94,8% (erro = 5,2%) e 96,7% (erro = 3,3%).

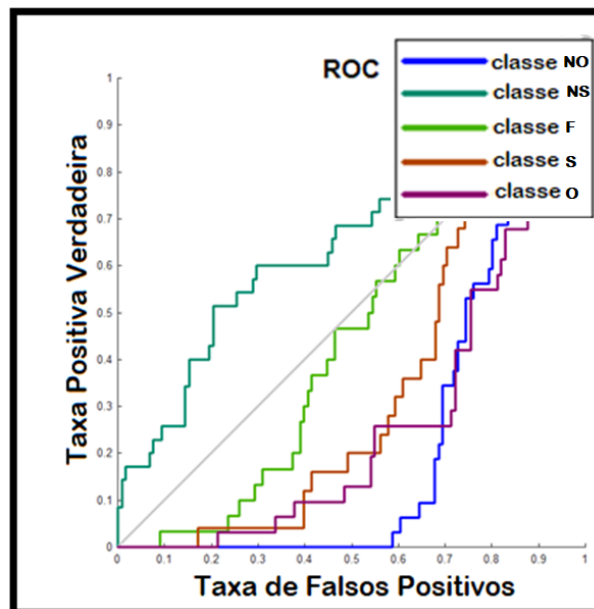
Em comparação, quando uma RNA treinada na classificação de um eixo específico (exemplo: eixo-X) e testada classificando os sinais de um eixo diferente (eixo-Y) os resultados na performance da RNA são insuficientes para a correta classificação, como demonstra a Tabela 15 (matriz de confusão) e Figura 50 (ROC).

Tabela 15 – Matriz de confusão da RNA X classificando os sinais do eixo-Y.

<b>Sinal Classificado</b>	<b>NO</b>	0 0.0%	0 0.0%	17 11.1%	0 0.0%	26 17.0%	0.0% 100%
	<b>NS</b>	1 0.7%	6 3.9%	0 0.0%	1 0.7%	0 0.0%	75.0% 25.0%
	<b>F</b>	6 3.9%	4 2.6%	1 0.7%	1 0.7%	0 0.0%	8.3% 91.7%
	<b>S</b>	6 3.9%	11 7.2%	0 0.0%	0 0.0%	0 0.0%	0.0% 100%
	<b>O</b>	19 12.4%	14 9.2%	12 7.8%	23 15.0%	5 3.3%	6.8% 93.2%
		0.0% 100%	17.1% 82.9%	3.3% 96.7%	0.0% 100%	16.1% 83.9%	7.8% 92.2%
	<b>NO</b>	<b>NS</b>	<b>F</b>	<b>S</b>	<b>O</b>	<b>Classe Alvo</b>	

Fonte: O autor (2017).

Figura 50 – Receiver Operating Characteristic da RNA X classificando os sinais do eixo Y.



Fonte: O autor (2017).

Assim, RNAs que utilizem os sinais dos três eixos, X, Y e Z, para caracterizar cada uma das 5 classes possuem um percentual de acerto inferior as RNAs treinadas



para eixos específicos, especialmente na classificação dos eixos X e Y, fato que justifica a utilização de RNAs especializadas.

#### 4.4 DISCUSSÃO E INTERPRETAÇÃO DOS RESULTADOS.

O eixo-Z, aquele que mede a aceleração no sentido da força gravitacional terrestre, quando comparado com o resultado dos demais eixos na pontuação por  $\sigma_{Crr}$ , obteve valores significativamente mais altos que os demais eixos. E quando analisamos a matriz de confusão gerada pelos coeficientes de correlação entre os Alvos criados e os sinais de entrada (Figura 64), vemos um padrão similar ao número de falsos positivos obtidos pela RNA XYZ.

Na Tabela 16 vemos que as classificações incorretas ocorrem com maior frequência, essas circulas em amarelo, nas classes onde os coeficientes de correlação partilham um valor alto. Por exemplo, no caso da classe (NO), essa foi classificada incorretamente três vezes com a classe (NS), a classe (NS) por sua vez foi classificada incorretamente mais vezes com a classe (NO) e a classe (S). Já a classe (O) foi sete vezes falsamente classificada como a classe (F). Fato esse que corrobora com os resultados obtidos na comparação de coeficientes de correlação entre os sinais (Tabela 12).

Tabela 16 – Matriz de confusão da RNA XYZ e suas classificações incorretas.

<b>Sinal Classificado</b>	<b>NO</b>	90 19.6%	3 0.7%	4 0.9%	1 0.2%	1 0.2%	90.9%
	<b>NS</b>	3 0.7%	98 21.4%	3 0.7%	4 0.9%	0 0.0%	90.7%
	<b>F</b>	0 0.0%	0 0.0%	78 17.0%	0 0.0%	7 1.5%	91.8%
	<b>S</b>	2 0.4%	4 0.9%	1 0.2%	70 15.3%	1 0.2%	89.7%
	<b>O</b>	1 0.2%	0 0.0%	4 0.9%	0 0.0%	84 18.3%	94.4%
			93.8%	93.3%	86.7%	93.3%	90.3%
		6.3%	6.7%	13.3%	6.7%	9.7%	8.5%
		<b>NO</b>	<b>NS</b>	<b>F</b>	<b>S</b>	<b>O</b>	
		<b>Classe Alvo</b>					

Fonte: O autor (2017).



Na Tabela 17 vemos a matriz de confusão do melhor classificador desenvolvido por Groh e colaboradores (2015), Bayes Ingênuo = 97,8% de acerto, 60 operações/segundo. Vemos que o padrão de falsos positivos (circulados em amarelo) segue a mesma tendência em ambos os estudos. A RNA XYZ demonstra uma dispersão similar, isso era esperado já que os sinais utilizados nesse estudo foram baseados no trabalho realizado pelo estudo citado (Groh et al, 2015).

Tabela 17 – Matriz de confusão do classificador Bayes Ingênuo .

predicted	true					360
	O	N	K	H	P	
O	33	1	0	0	0	0
N	2	31	0	0	0	0
K	0	0	36	0	0	1
H	0	0	0	37	0	0
P	0	0	0	0	35	1
360	0	0	0	0	0	49

Fonte: O autor (2017).

O classificador RNA Z (Tabela 14) obteve um percentual de acerto de 98,3%, com um resultado de duas classificações incorretas em 153 amostras. A performance dos dois métodos de classificação foi avaliada através do tempo necessário para que a classificação fosse executada. Na Tabela 18 vemos performance dos scriptst de classificação, Correlação Cruzada (Xcorr) e RNA, expressa pelo tempo estimado (segundos) para classificar um certo número de amostras.

Tabela 18 – Performance dos classificadores (Xcorr e RNA).

	RNA/treino	RNA/teste	Xcorr	Xcorr	Xcorr
<b>Segundos</b>	0,1 – 0,8	0,001 – 0,003	0,004 – 0,006	0,045 – 0,050	0,068 – 0,070
<b>Nº de amostras</b>	123	15	3	6	9

Fonte: O autor (2017).

Como vemos na Tabela 18, as RNAs classificam com uma velocidade maior (até  $10^{-3}$  segundos) e um número maior de sinais que o método que utiliza apenas a correlação cruzada e coeficientes de correlação entre sinais, onde a performance reduz ( $\pm 50 \times 10^{-3}$  segundos) consideravelmente quando necessário determinar mais do

que três sinais de aceleração (uma manobra), fator esse que prejudicaria a velocidade de um classificador com um grande acervo de Alvos.

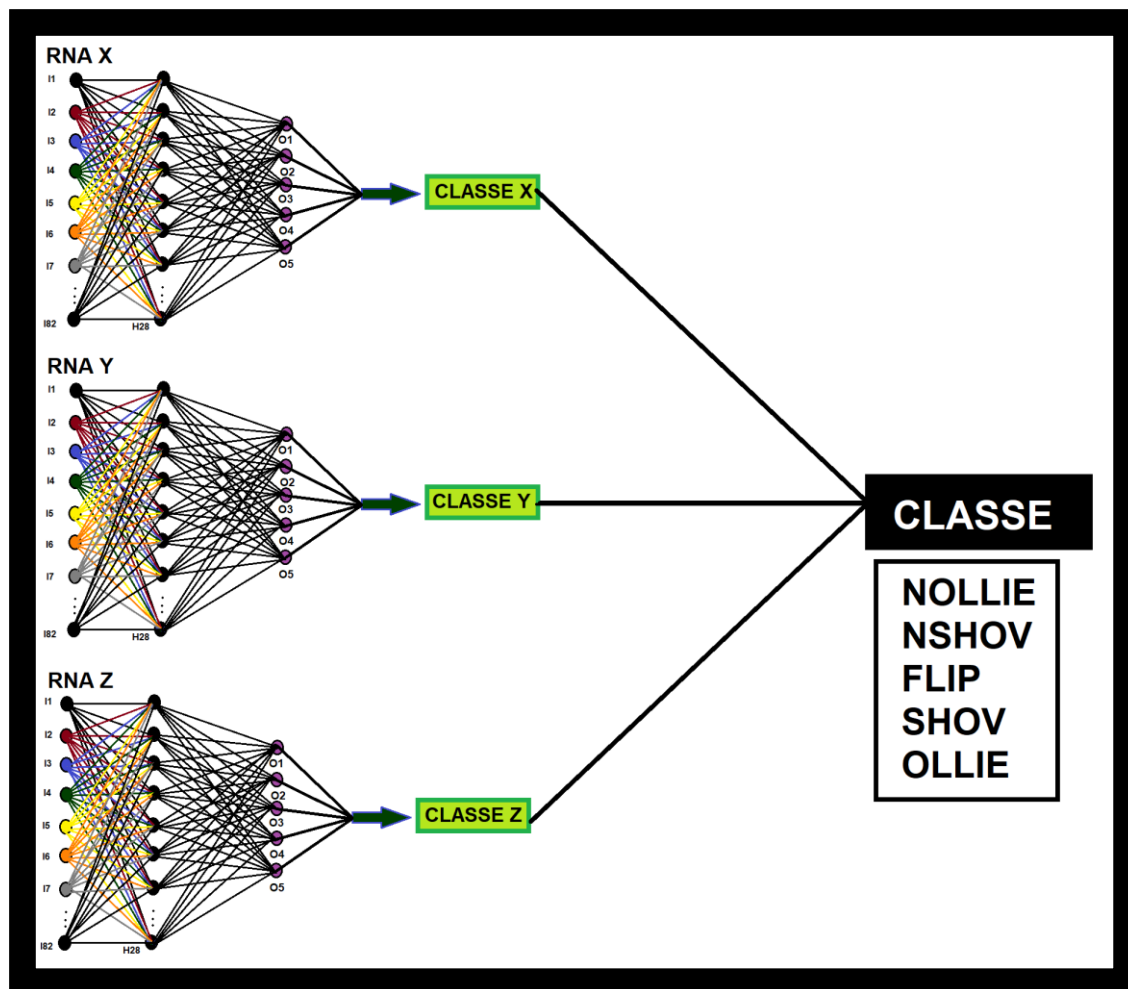
No estudo de Groh e colaboradores, (2015), de cada manobra foram calculadas 54 características (*features*), como média, variância, kurtosis, densidade espectral, espectro de frequências, entre outros parâmetros. Essas extrações eram feitas em cada sinal dos três acelerômetros, giroscópios e ainda a normalização dos dados dos acelerômetros pelos giroscópios, o que gerava as 54 características.

Enquanto isso, o estudo de Anlauff e colaboradores, (2010), utilizou apenas os dados dos sensores inerciais (acelerômetro e giroscópio 3D) e do sensor FSR para processar sete características durante a classificação. O classificador desenvolvido para o *Tilt n' Roll* (Figura 9) provou ser uma aplicação em tempo real com um método eficiente de classificação em termos computacionais, podendo ser utilizado em smartphones modernos. Contudo o classificador era apenas apto a diferenciar duas classes de manobras, Ollie e Frontside Ollie através da discriminação por LDA (97% de acerto), já a classe *Bail* (manobra executada incorretamente) era avaliada pelo sensor de força (FSR).

Ambos os estudos ressaltam a necessidade de um classificador que possa abranger um número maior de classes, sem perder a eficiência computacional, A velocidade de execução das redes treinadas,  $10^{-3}$  segundos, foi possível dado ao pequeno número de dimensões utilizadas, redução de dimensões é uma área de suma importância em aprendizado de máquina. Com os dados provenientes de um eixo de aceleração (eixo-Z), obtivemos um percentual de erro de 1,3 %, e analisando os três eixos do acelerômetro com RNAs especializadas, podemos diminuir percentual para 0,04%, como mostra a Figura 51.

Com a tecnologia de detecção de movimentos encontrando-se amplamente disponível, e os classificadores desenvolvidos alcançando um bom desempenho ao registrar/classificar eventos reais e artificiais, a tecnologia desenvolvida é apta para ser aplicada em coletas reais com um número maior de classes e amostras. Contudo, quando trabalhamos com grandes grupos de dados e redes neurais de multi-camadas treinados de maneira supervisionada, podemos perder eficiência dado o *overfitting*. A classificação incorreta de classes dispares é um indicador de alta densidade na separação das classes.

Figura 51 – Arquitetura do classificador formado por RNAs especializadas.



Fonte: O autor (2017).

Uma possível alternativa para solucionar este problema seria utilizar redes neurais de arquitetura profunda e treinamento não supervisionado (*deep learning*), para que representações mais eficientes pudessem ser observadas durante o processamento dos dados. Representações de aprendizado (*Representation learning*) é uma área ativa em pesquisa no campo de aprendizado de máquina (BENGIO et al, 2012), pois representações extremamente úteis e abstratas podem ser encontradas por redes neurais profundas, e essas utilizadas para aprimorar nossa compreensão do fenômeno estudado.

A melhor solução talvez se encontre em uma mescla de treinamento supervisionado e não supervisionado. O estado da arte em algoritmos de aprendizagem profunda encontra-se na proposta de treinamento semi-supervisionado (*Pseudo Label*), onde existe o treinamento simultâneo de maneira não supervisionada e supervisionada, fator que age como um regularizador da entropia, melhorando a performance de redes profundas (DONGHYUN, 2013). Isso favorece baixa densidade

na separação de classes e obtém resultados promissores com um baixo custo computacional e uma grande capacidade de classificação para grupos amostrais com diversos padrões.

Esse conceito envolve aliar um pequeno auxílio (supervisão) do especialista na caracterização dos dados, porém, permitindo que redes neurais utilizem seu poder computacional para explorar o espaço de características. Com o contínuo avanço na área de aprendizado de máquina e IA (inteligência artificial), ferramentas promissoras podem ser desenvolvidas, e o assessoramento homem/máquina (CAA) pode auxiliar a desenvolver a próxima geração de controles e interfaces de simulação. Novos métodos de aprendizado e arquitetura, como *Cooperative inverse reinforcement learning* (CIRL) (MENELL et al, 2016), e *Imagination-Augmented Agents* (I2As) (WEBER et al, 2017), são técnicas que exploram o conceito de aprendizagem semi-supervisionada com promissores resultados.

A seguir é proposta uma aplicação da tecnologia desenvolvida, utilizando os métodos desenvolvidos para criar uma ferramenta (pro-tótipo) de skate/controle para estudo e treinamento de manobras de Street. A proposta serve para estudo futuros com coletas reais em praticantes, e não praticantes, do Skate.

#### 4.5 APLICAÇÃO E PROPOSTA PARA ESTUDOS FUTUROS

Como foi dito anteriormente na fundamentação teórica, SIMULAÇÕES INTERATIVAS E JOGOS, *exergames* são uma ferramenta para desenvolvimento seguro de atividades físicas onde a simulação procura aproximar o usuário da experiência real. Contudo até o momento as interfaces criadas para serem a ponte entre o fenômeno real, Skate, e a simulação não são versáteis o suficiente para representar toda a gama de movimentos que o Skate oferece (ANLAUFF et al, 2010).

O de classificação desenvolvido neste estudo apresenta um bom desempenho na tarefa de classificar e discernir diferentes manobras/classes, classes essas que podem vir a representar diferentes comandos e ações. IMUs ainda podem oferecer através da integração do sinal disponibilizado pelo sensor (aceleração), parâmetros como a velocidade, a localização (altura e distância alcançada), e a força aplicada durante cada manobra. Todas essas informações são dados biomcânicos úteis tanto para o desenvolvimento de uma interface que forneça feedback para seus usuários, quanto para enriquecer uma simulação interativa.

Em estudos futuros, deve-se almejar a montagem de um banco de dados contendo variadas classes de manobras amostradas de maneira criteriosa. É possível que características não classificadas sejam encontradas utilizando os métodos especificados anteriormente. Talvez a diferença entre execuções de manobras da

mesma classe revele novos parâmetros a serem considerados na aprendizagem do Skate.

Acredita-se que os métodos de aquisição e classificação desenvolvidos neste estudo sejam capazes de implementar o Simulador mecânico apresentado anteriormente. Com o intuito de aperfeiçoar o conceito de Simulação de manobras de Skate, propomos uma aplicação que redefine certos conceitos propostos pelo Simulador mecânico, e forneça uma solução mais prática, eficiente, e com um menor custo.

Comumente no Skate shapes são utilizados na aprendizagem de certas técnicas de Street Skate devido ao fato de que sem o acoplamento dos eixos e rodas, a tábua de madeira se torna um artifício muito mais seguro ao se manusear com os pés. A proposta idealizada consiste de um suporte que possa ser fixado no lugar dos eixos, e forneça uma distância confortável entre o nose/tail e o solo ( $\pm 16$  cm), e proteja o sistema de aquisição em seu interior. Um protótipo foi modelado utilizando o software SolidWorks 2016 (Figura 52), utilizando lâminas de fibra de madeira de densidade média (MDF) cortadas por laser e fixadas por cola de madeira e parafusos/porcas M3 (25mm), M5(35mm) e M8 (200mm) (Figura 53).


Figura 52 – Modelo tridimensional do suporte renderizado pelo SolidWorks 2016.



Fonte: O autor (2017).

O suporte possui espaço para acomodar o sistema de aquisição e bateria em sua face superior, o sistema de aquisição por sua vez utiliza de um radiotransmissor Bluetooth para a transmissão dos dados do acelerômetro triaxial para uma estação de controle (console/celular).

Figura 53 – Montagem do suporte em MDF.



Fonte: O autor (2017).

Este suporte permite a criação de uma plataforma de treinamento e estudo, onde divesos movimentos e manobras podem ser executados e a limitação das movimentações é pouco restringida, dada semelhança a um skate convencional (Figura 54). Devido a ausência de deslocamento do skate em relação ao eixo Y a experiência pode ser contida em um ambiente restrito. Testes mostraram que todas as classes de manobras avaliadas neste estudo preservam as mesmas características e padrões durante sua análise e classificação, sejam elas executadas em movimento ou estaticamente.

Figura 54 – Montagem do suporte/sistema de aquisição no shape.



Fonte: O autor (2017).

A ausência de movimentação do skate auxilia o usuário a se equilibrar com maior facilidade, o skate de treinamento fornece uma redução de todas as acelerações e perturbações que possam interferir no equilíbrio do usuário durante a execução de manobras, isso permite que o indivíduo possa aperfeiçoar gestos motores e treinar a coordenação oculo pedal responsável por diversas técnicas de Street de maneira simplificada, e com feedback sendo fornecido de maneira assessorada (CAA).

Sendo possível a aplicação dos métodos desenvolvidos neste estudo em tecnologias mobile (celulares, smartphones, tablets), como feito por Anlauff e colaboradores, (2010), seria possível o desenvolvimento de um aplicativo que juntamente com o suporte/sistema de aquisição fornecesse uma experiência didática e educativa para seus usuários.

## **5. CONCLUSÃO**

A popularização do Skate como um movimento cultural permitiu que sua prática alcançasse diversos países, e atualmente o skate é um dos mais populares esportes no Brasil. Em 2020 o Skate será projetado de maneira global através dos jogos olímpicos de Tokyo, algo que com certeza irá estimular o desenvolvimento do esporte em uma escala global.

O desenvolvimento do Skate através de métodos cada vez mais didáticos e seguros deve ser almejado pelos profissionais de saúde pertencentes a cultura Skatista. E com o intuito de buscar inovações para o Skate que este estudo foi realizado. Unindo especialidades de diversas áreas do conhecimento, e com embasamento nos trabalhos que vêm sendo realizados na área, exploramos métodos possivelmente nunca utilizados para analisar o fenômeno Skate.

A miniaturização de sistemas microeletrônicos integrados (MEMS) permite o desenvolvimento de sistema de detecção e sensores extremamente portáteis e eficientes, enquanto redes neurais artificiais, uma das áreas mais promissoras no desenvolvimento de AI (Inteligência Artificial), são ferramentas extremamente úteis quando podemos fornecê-las as corretas condições de treinamento e arquitetura. Redes Neurais podem fornecer soluções para diversos tipos de problemas, apenas sendo necessário a adequada interpretação e manipulação do problema.

A classificação discriminada pelos eixos provou ser uma técnica de classificação mais eficiente que que as demais, além de obter um bom desempenho, a redundância desse procedimento garante um mínimo percentual de erro. Com as tecnologias disponibilizadas atualmente podemos criar ferramentas extremamente úteis, especialmente em aplicações que envolvam sensores e reconhecimento de padrões. Diversos esportes podem se beneficiar desse tipo de tecnologia, especialmente aqueles cuja a movimentação de algum instrumento, ou do próprio corpo, pelo espaço seja um fator chave para aquela modalidade, como o próprio TPTSR, parkur, tênis, BMX, ginástica, artes marciais, entre outros.

Redes Neurais Artificiais são uma poderosa ferramenta para tarefas complexas, atualmente o conceito de aprendizado de máquina e aprendizagem profunda são o pináculo científico em pesquisa para desenvolvimento de inteligência

artificial. É importante que essa tecnologia seja utilizada para assessorar áreas biomédicas, aonde a classificação e reconhecimento de padrões é fundamental para o aprimoramento de nossas capacidades.

A boa interpretação do problema sempre impactará de forma positiva o desenvolvimento, concepção e construção dos métodos de solução. Esta interpretação é tão importante na obtenção de um bom resultado quanto a qualidade das ferramentas utilizadas no processo. Foram necessários conhecimentos tanto na natureza do fenômeno estudado, Skate, nas tecnologias de captura e quantização de fenômenos físicos, acelerometria, processamento de sinais, e por fim *Machine learning* para desenvolver um classificador eficiente.

Da mesma maneira como a aprendizagem motora humana passa por diversos estágios de maturação e desenvolvimento, foi necessário conceitos similares de feedback e aprendizagem supervisionada para cumprir os objetivos propostos neste estudo. O refinamento de qualquer disciplina tende a passar por estas etapas, mas que culminemos sempre para o mesmo propósito, a solução mais eficiente para o problema atacado.



## REFERÊNCIAS

- AAOS – *American Academy of Orthopaedic Surgeons: OrthoInfo – Skateboarding Safety*. Disponível em:  
<http://orthoinfo.aaos.org/topic.cfm?topic=a00273>. Acesso em: 04 ago. 2016.
- ADAMS, J. A closed-loop theory of motor learning. **Journal of Motor Behavior**, v. 3, p.111–49, 1971.
- ADI, E. et al. Skateboarding through 3D Simulations of Angle Rotations. **Journal of Information Technology Education**, v. 9, p. 217 – 234, 2010.
- ALDRICH, C. **Learning by doing: A comprehensive guide to simulations, computer games, and pedagogy in e-learning and other educational experiences**. Pfeiffer, San Francisco, 2005.
- ANLAUFF, J. et al. A Method for Outdoor Skateboarding Video Games. Proceeding: **ACE '10 Proceedings of the 7th International Conference on Advances in Computer Entertainment Technology**, p. 40 – 44. Taipei, Taiwan, 17 – 19 de Novembro, 2010. doi>10.1145/1971630.1971642
- AYERS, S.F. et al. An examination of the contributions of practice, demonstrations and cuing, and direct instruction to skill learning. **Research Quarterly for Exercise and Sport**, v. 74, p. A–35, 2003.
- BAO, L.; INTILLE, S. Activity recognition from user-annotated acceleration data. **Pervasive Computing**, p. 1– 17, 2004.
- BEALE, R; JACKSON, T. **Neural computing: an introduction**. Bristol, Adam Hilger, 1990.
- BARBOUR, N.; SCHMIDT, G. Inertial sensor technology trends. **IEEE Sensors Journal**, v.1, n. 4, p. 332, 2001.
- BATTOU, L; BENGIO, Y. o. **Convergence properties of the kmeans algorithm**. In: *Advances in Neural Information Processing Systems*. 1995.

BEER, F. P.; JOHNSTON, E. R. **Mecânica Vetorial para Engenheiros: Cinemática e Dinâmica**, 5ª ed, Makron Books, São Paulo, 1994.

BENGIO, Y; COURVILLE, A; VINCENT, P. **Representation learning: A review and new perspectives**. arXiv, 2012. Available from: <https://arxiv.org/pdf/1206.5538.pdf>

BERNSTEIN, J. **An Overview of MEMS Inertial Sensing Technology. Sensors, 2003**. Disponível em: <http://www.sensorsmag.com/sensors/acceleration-vibration/an-overview-mems-inertial-sensing-technology-970>. Acessado em: 05 Jan. 2017.

BRAGA, A. P. et al. **Redes Neurais Artificiais: Teoria e Aplicações**. Editora LTC, Rio de Janeiro, p. 67 – 85, 2000.

BRANDÃO, L. **Entre a marginalização e a esportivização: Elementos para uma história da juventude skatista no Brasil**. Revista de História de Esporte, v. 1, n. 2, dezembro de 2008.

BRITTO, E. **A Onda Dura – 3 Décadas de Skate no Brasil**. Editora Parada Inglesa NPL, Brasil, p. 114, 2000.

BROKER, P. CRAWLEY, J. D. **Advanced Sport Technologies: Enhancing Olympic Performance**, 19º ISBS, p. 323 – 327, 2001.

BROOKFIELD, S. D. **Understanding and facilitating adult learning**. San Francisco: Jossey-Bass, 1986. ISBN 1-55542-355-8.

BRIDGMAN, S; COLLINS, L.; COLLINS, D. F. **Human body motion in the ollie**. The Physics Teacher, College Parks, n. 30, p. 489 – 499, 1992.

BUDYNAS, R. G; NEISBETT, J. K. **Elementos de Máquinas de Shigley**. Editor McGraw Hill, New York, USA. 10ª edição, p. 285 – 288, 2015.

CAO, Y.; ZU, J. Review of the Gyroscope Free Strap-down Inertial Navigation System. **ICCSM: Computer Application and System Modeling**. Tayuan, v. 6, p. 413–417, Outubro, 2010.

CBSk – Confederação Brasileira de Skate. **Mercados do Skate**. Disponível em: <http://www.cbsk.com.br/paginas/mercados-do-Skate-no-brasil-e-no-mundo>. Acesso em: 24 Dec. 2016.

CBSk – Confederação Brasileira de Skate. **História do Skate no Brasil**. Disponível em: <http://www.cbsk.com.br/paginas/historia-do-Skate-no-brasil>. Acesso em: 24 Dec. 2016.

CBSk – Confederação Brasileira de Skate. **História do Skate no Mundo**. Disponível em: <http://www.cbsk.com.br/paginas/historia-do-skate-no-mundo>. Acesso em: 24 Dec. 2016.

CBSk – Confederação Brasileira de Skate. **Dados do Esporte**. Disponível em: [http://173.255.202.190/uploads/ckeditor/attachments/8/Pesquisa\\_Datafolha\\_2009.pdf](http://173.255.202.190/uploads/ckeditor/attachments/8/Pesquisa_Datafolha_2009.pdf). Acesso em: 24 Dec. 2016.

CBSk – Confederação Brasileira de Skate. **Modalidade Street**. Disponível em: <http://www.cbsk.com.br/modalidades/street>. Acesso em: 24 Dec. 2016.

CADOTTI, C. et al. Lower limb force and performance in skateboarding: an exploratory study. **Revista Brasileira de Ciências do Esporte**, Florianópolis, v. 34, n. 3, p. 697– 711, 2012.

CALVO – MERINO, B. et al. Seeing or doing? Influence of visual and motor familiarity in action observation. **Current Biology**, v. 16, n.19, p. 1905 – 1910, 2006.

CARVALHO, A. **Capacidades Motoras – elementos fundamentais do Rendimento Desportivo**. Treino Desportivo, v. 5, p. 24 – 31, 1987.

CESARI, P. et al. Might as Well Jump: Sound Affects Muscle Activation in Skateboarding. **PLoS ONE**, v. 9, n. 3, e90156, 2014.

DOI:10.1371/journal.pone.0090156.

CHEN, J. et al. Gyroscope Free Strapdown Inertial Measurement Unit by Six Linear Accelerometers. **Journal of Guidance, Control e Dynamics**, v. 17, n. 2, p. 286 – 290, 1994.

CUARELLI, Gilberto. **Estimação de parâmetros da marcha humana a partir de medições feitas por acelerômetros e giroscópios e uso de mecanismo de referência**. Dissertação de Mestrado, Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP. São Paulo, 2013.

CUSUMANO, J. P.; CEARI, P. Body–goal variability mapping in an aiming task. **Biological Cybernetics**, v. 94, n. 5, p. 367 – 379, 2006.

DA SILVEIRA, Fernando Lang. **Determinando a aceleração gravitacional**. Instituto de Física, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006. Disponível em:  
[http://www.fisica.net/fernandolang/determinando\\_a\\_aceleracao\\_gravitacional\\_g.pdf](http://www.fisica.net/fernandolang/determinando_a_aceleracao_gravitacional_g.pdf). Acesso em: 03 jan. 2017.

DA SILVA, FERNANDO. **Reconhecimento de movimentos humanos utilizando um acelerômetro e inteligência computacional**. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, Mestre em Engenharia, 2013.

DEHART, R. L. The Historical Perspective. In: DeHart, R.L. **Fundamentals of Aerospace Medicine 2<sup>a</sup>**. Baltimore: William & Willins, p. 3 – 22, 1996.

DONGHYUN, L. **Challenges in Representation Learning (WREPL): Pseudo-Label : The Simple and Efficient Semi-Supervised Learning Method for Deep Neural Networks**. ICML 2013 Workshop : Atlanta, Georgia, USA, 2013.

ERMES, M. et al. IEEE transactions on information technology in biomedicine: **IEEE Engineering in Medicine and Biology Society**. v. 12, n. 1, p. 20–6, 2008.

EVERETT, W.W. Skatepark injuries and the influence of skatepark design: a one year consecutive case series. **Journal of Emergency Medicine**, v. 23, p. 269 – 274, 2002.

FITTS, P. Perceptual–motor skills learning. In: MELTON, A.W., ed. **Categories of human learning**. New York, Academic Press, p. 243 – 8 5, 1964.

FRANKLIN, B. A. **ACSM's Guidelines for Exercise Testing and Prescription**, 6th Edition. Lippincott Williams & Wilkins, Baltimore, Maryland, p. 145 – 146, 2000.

FREEMAN, R.; LEWIS, R. **Planning and Implementing Assessment**, Kogan, p. 77 – 141, 1998.

FREDERICK, E. C. et al. Biomechanics of Skateboarding: kinetics of the Ollie. **Journal of Applied Biomechanics**, v. 22, n. 1, p. 33 – 40, 2006.

FORSMAN, L.; ERIKSSON, A. Skateboarding Injuries of today. **British Journal of Sports Medicine**, v. 35, n. 5, p. 325 – 328, 2001.

FOUNTAIN, J. L.; MEYERS, M. C. Skateboarding Injuries. **Sports Medicine**, v. 22, n. 6, p. 360 – 6, 1996.

GEIGER, W. et al. Decoupled Microgyros and the Design Principle DAVED. **Sensors and Actuators**, v. A, n. 95, p. 239, 2002.

GENTILE, A.M. A working model of skill acquisition with application to teaching. **Quest**, v.17, p. 2 – 23, 1972.

GOODMAN, J.S.; WOOD, R.E.; HENDRICKX, M. Feedback specificity, exploration and learning. **Journal of Applied Psychology**, v. 89, p. 248 – 262, 2004.

GROH, B. et al. **IMU – Based Trick Classification in Skateboarding**. KDD Workshop on large – Scale Sports Analytics, Sydney, Australia, 2015.

GUYTON, A.C. **Fisiologia Humana**. 7<sup>a</sup> ed., Rio de Janeiro, Ed. Interamericana, p. 420–438, 1989.

GYLLENSTEN, C. I. **Physical Activity Recognition in Daily Life using a Triaxial Accelerometer**. Dissertação de Mestrado, Royal Institute of Technology, Stockholm, 2010.

HALLIDAY, D. et al. **Fundamentos de Física 8<sup>a</sup>– LTC**, V. 1, 2 e 3. Rio de Janeiro, 2008.

HALLIDAY, D. et al. **Fundamentals of physics extended**. John Wiley & Sons, 2010.

HASSON, C. J. et al. Neuromechanical strategies employed to increase jump height during the initiation of the squat jump. **Journal of Electromyography and Kinesiology**, New York, v. 14, n. 4, p. 515 – 521. 2004.

HAYKIN, S. **Redes Neurais: Princípios e Prática 2ª**. Editora Bookman, Porto Alegre, 2001.

HECHT, N. R. **Neurocomputing**. HNC In: University of California, Department of Electrical and Computer Engineering, San Diego, 1998.

HECHT, N. R. Theory of the Backpropagation Neural Network. **Neural Networks** v. 1, n. 1, p. 593 – 605, 1989.

HETZLER, R. et al. Selected Metabolic Responses to Skateboarding. **Journal of Research Quarterly for Exercise and Sport**, v. 82, n. 4, p. 788 – 793, 2001. Disponível em: <http://dx.doi.org/10.1080/02701367.2011.10599816>. Acessado em: 24, dec. 2016.

HONEY, P.; MUNFORD, A. **The Manual of Learning Styles, Maidenhead**, Peter Honey, 1992.

JITAO, Y. A Novel Design of NGIMU. **Education Technology and Training, Shanghai**, v. 2, p. 267–269, 2008.

KARANTONIS, et al. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. **IEEE transactions on information technology in biomedicine: a publication of the IEEE Engineering in Medicine and Biology Society**, v. 10, n. 1, p. 156–67, 2006.

KE, F. Computer games application within alternative classroom goal structures: cognitive, metacognitive, and affective evaluation. **Educational Technology Research and Development**, v. 56, n. 5, p. 539 – 556, 2008.

KIONIX. **Products**. Disponível em: <http://www.kionix.com/>. Acessado em: 05 jan. 2017.

KOHLER, E. et al. Hearing sounds, understanding actions; action representation in mirror neurons. **Science**, v. 297, n. 5582, p. 846 – 848, 2002.

KOHONEN, T. **Self–Organization and Associative Memory 2ª Edition**. Springer, p. 161–177, 1988.

KOLB, D. **Experiential learning: Experience as the source of learning and development**. Englewood Cliffs, NJ: Prentice–Hall, 1984. ISBN 0–13295–261–0.

KYLE, S. B. et al. Skateboard–associated injuries: Participation–based estimates and injury characteristics. **Journal of Trauma**, v. 53, p. 686 – 690, 2002.

LE BOUCH, J. O Desenvolvimento Psicomotor do nascimento até 6 anos. Porto Alegre. **Artes Médicas**, p. 150, 1992.

LEWIN, K. **Field theory in social science: selected theoretical papers**. New York, Harper & Row, 1951.

LIAO, C.M.; MASTERS, R.S.W. Analogy learning: a means to implicit motor learning. **Journal of Sports Sciences**, v. 19, p. 307–319, 2001.

MACHADO, A. **Neuroanatomia Funcional**. 3ª ed. Rio de Janeiro: Atheneu, p. 60-246, 2013.

MAGILL, R.A. **Motor learning: concepts and applications 3ª**. Dubuque, Wm.C.Brown, 1989.

MAGILL, R. A. et al. Verbal knowledge of results as redundant information for learning an anticipation timing skill. **Human Movement Science**, v. 10, n. 4, p. 485 – 507, 1991.

MAGIL, R. A. **Aprendizagem motora: conceitos e aplicações**. São Paulo, Editora Edgard Blucher Ltda, 2000.

MARC, B. et al. SwimMaster: A Wearable Assistant for Swimmer. **UbiComp 9**, p. 215 – 224, 2009.

MARQUES, A. et al. Aptidão Física. In: FACDEX, **Desenvolvimento Somato-Motor e Factores de Excelência Desportiva na População Portuguesa**.

Relatório Parcelar da Área do Grande Porto. ME-GCDE. Lisboa, 1992.

MCCORD, N. M.; ILLINGWORTH, W. T. **How Do You Move from Theory to Applications? A Practical Guide to Neural Nets**. Sponsoring Editor Ted

Buswick, USA, p.159–163, 1990.

MCKENZIE, L. B. et al. Epidemiology os Skatebarding–related injuries sustained by children and adolescents 5–19 years of age and treated in US emergency departments: 1990 through 2008. **Injuries Epidemiology**, v. 3, n. 1, p. 10, 2016.

MEINEL, K. Motricidade II. **O desenvolvimento motor do ser humano**. Rio de Janeiro. Ao Livro Técnico, 1984.

MEINELL, D. H. et al. **Cooperative Inverse Reinforcement Learning**. NIPS - 30th Conference on Neural Information Processing Systems. Barcelona, Spain, 2016. Disponível em: <https://arxiv.org/pdf/1606.03137.pdf>

MULLER, F. et al. Taxonomy of exertion games. Em: **Proceedings of the 20th Autralian Conferenceon Computer–Human Interaction: Designing for Habitus and Habitat**, ACM, p. 263 – 266, 2008.

NAGANO, A. et al. Force, Work and power output of lower limb muscles during human maximal–effort countermovement jumping. **Journal of Electromyography and Kinesiology**, v. 15, n. 4, p. 367 – 376, 2005.

NEGRINE, A. **A coordenação psicomotora e suas implicações**. Palotti, Porto Alegre, 1987.

NEWTON, I. **Mathematical Principles of Natural Philosophy**. Translated by Andrew Motte (1729). Revised by Florian Cajori. Berkeley: University of California Press, p. 2 – 28, 1934.

OLIVEIRA, J.A.A. et al. Otorrinolaringologia. Princípios e Prática: a fisiologia clínica da audição. 1ª ed. Porto Alegre: Artes Médicas, p. 238-48, 1994.



OLIVEIRA, Ângelo Rocha de. **Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão**. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora. Juiz de Fora, MG, Agosto, 2005.

PAPASTERGIOU, M. Digital game-based learning in high school computer science education: Impact on educational effectiveness and student motivation. **Computers and Education**, v. 52, n. 1, p. 1 – 12, 2009.

PAZOS, F. **Automação de Sistemas & Robótica**. Axel Books do Brasil Editora, Rio de Janeiro, 2002.

PELLEGRINI, A.M. A aprendizagem de habilidades motoras !:O que muda com a prática? **Revista Paulista de Educação Física**, São Paulo, v. 3, p. 29 – 34, 2000.

PIEKARZIEVCZ, Luiz Estanislau. **Efeitos do Feedback Extrínseco Aumentado no processo de aprendizagem de uma habilidade motora fechada**. Dissertação de Mestrado, Universidade Federal do Paraná, Curitiba 2004.

PERRY, J. **Análise de Marcha: Marcha patológica**. Manole, São Paulo, 2005.

POCIELLO, C. Os desafios da leveza: as práticas corporais em mutação. Em **SANT'ANNA, D. B. (orgª). Políticas do corpo: elementos para uma história das práticas corporais**. São Paulo: Editora Estação Liberdade, p. 115 – 120, 1995.

PROENÇA, J.E. **Efeitos da variação temporal do conhecimento de resultado na aprendizagem de uma habilidade motora discreta simples**. Dissertação de mestrado, Universidade Federal de São Paulo, p. 63, 1988.

PULVERMÜLLER, F. et al. Motor cortex maps articulatory features of speech sounds. **USA, Proceedings of the National Academy of Sciences**, v. 103, n. 20, p. 7865 – 7870, 2006.

QIN, F. et al. A New Scheme of Gyroscope Free Inertial navigation System Using 9 Accelerometers. In: **ISA – International Workshop on Intelligent Systems and Applications**, 2009.

REED, C. **Skateboarding: the sport explained**, 2002. Disponível em: [http://skateboarddirectory.com/articles/480283\\_skateboarding\\_the\\_sport.html](http://skateboarddirectory.com/articles/480283_skateboarding_the_sport.html). Acesso em: 25 jan. 2016.

REYNELL, E.; THINYANE, H. Hardware and software for skateboard trick visualisation on a mobile phone. **SAICSIT 12**, p. 253 – 261, 2012.

REZENDE, S. O. et al. **Sistemas inteligentes: Fundamentos e Aplicações**. Editora Manole Ltda, p. 141 – 69, 2003.

RIEBER, L. Multimedia learning in games, simulations, and microworlds. In R. E. Mayer (Ed.), **The Cambridge Handbook of Multimedia Learning**. New York, Cambridge University Press, p. 549 – 567, 2005.

RIEDMILLER, M.; BRAUN, H. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. **IEEE International Proceedings on Neural Networks, San Francisco**, p. 586 – 591, 1993.

RONEN, M.; ELIAHU, M. Simulation—a bridge between theory and reality: The case of electric circuits. **Journal of Computer Assisted Learning**, v.16, n. 1, p. 14 – 26, 2000.

SALOME, L., R. Constructing authenticity in contemporary consumer culture: the case of lifestyle sports. **European Journal for Sport and Society**, v. 7, n. 1, p. 69 – 87, 2010.

SANTOS, M. M. L. **Efeitos do Feedback extrínseco na performance da manobra Ollie em skatistas do município de Irati-PR**. Monografia apresentada ao Curso de Graduação em Educação Física, da Universidade Estadual do Centro-Oeste, Irati, 2008.

- SANTOS, V. M. F. **Robótica Industrial**. Universidade de Aveiro, Aveiro, 2004.
- SCHILLING, D. et al. Equilíbrio posural e musculoesquelético de skatistas. **Cinergis**, v. 15, n. 1, 2014. Disponível em: <http://online.unisc.br/seer/index.php/cinergis/article/view/4853/3605>. Acesso em: 25 jan. 2016.
- SCHMIDT, R. A. **Aprendizagem e performance motora**. São Paulo, Ed. Movimento, p. 310, 1992.
- SHIRATORI, T.; LATASH, M. L. Anticipatory postural adjustments during load catching by standig subjects. **Clinical Neurophysiology**, v. 112, n. 7, p. 1250 – 1265, 2001.
- SILVA, Anderson Bráulio Nóbrega. **Um modelo de unidade de medida inercial utilizando três acelerômetros triaxiais**. Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, Programa de Pós-Graduação em Engenharia Elétrica. Rio Grande do Norte, Natal, 2013.
- SKOG, I.; HÄNDEL, P. A Versatile PC-Based Platform for Inertial Navigation. In: NORSIG: Nordic Signal Processing Symposium, 2006.
- STIENSTRA, J. et al. Embodying Complexity through Movement Sonification: Case Study on Empowering the Speedskater. **CHI'11, ACM Press**, p. 39 – 44, 2011.
- STMICROELECTRONICS. **Product, MEMS and sensors**. Disponível em: <http://www.st.com/en/mems-and-sensors.html>. Acessado em: 24 dec. 2016.
- SWINNEN, S.P. et al. Interlimb coordination: learning and transfer under different feedback condition. **Human Movement Science**, v. 16, p. 749 – 785, 1997.
- TESLER, P. **Asphalt acrobats**. Scientific American Presents. 2000.
- TODOROV, E.; JORDAN, M. I. Optimal feedback control as a theory of motor coordination. **Nature Neuroscience**, v. 5, n. 11, p. 1226 – 1235.

TOVAR, A. M. et al. Effect's os skateboarding gender on anterior posterior weight shift. **Conference Paper, American College of Sports Medicine, Orlando FL**. Maio, 2014. Disponível em:

[https://www.researchgate.net/publication/264975418\\_Effects\\_of\\_skateboarding\\_and\\_gender\\_on\\_anterior\\_posterior\\_weight\\_shift](https://www.researchgate.net/publication/264975418_Effects_of_skateboarding_and_gender_on_anterior_posterior_weight_shift). Acesso em: 24 dec. 2016.

TREDICI, T.J. Ophthalmology in Aerospace Medicine. In: **DeHart, R.L. Fundamentals of Aerospace Medicine 2ª ed.** Baltimore: William & Willins, p. 66 – 517, 1996.

TRITSCHLER, K. **Medida e avaliação em educação física e esportes.** Barrow & McGee. Manole, São Paulo, 2003.

**TSC – Tokyo 2020 Skateboarding Commission. Skateboarding in the Olympics, International Olympic Committee Announces Street and Park Events to Debut in Tokyo 2020.** Disponível em:

<http://skateboarding2020.com/wp-content/uploads/2016/08/TSC-Skateboarding-in-the-Olympics-announcement-FINAL-1.pdf>. Acesso em: 24 dec. 2016.

WANG, J. et al. Recognizing Human Daily Activities from Accelerometer Signal. **Procedia Engineering**, v. 15, p. 1780 – 1786, 2011.

WANG, Q. et al. A new scheme of non-gyro inertial measurement unit for estimating angular velocity. In: **IECON, 29th, 2003, Virginia. Industrial Electronics Society**, Virginia, v. 2, p. 1564 – 1567, 2003.

WEBER, T, et al. Imagination-Augmented Agents for Deep Reinforcement Learning. DeepMind ©. Disponível em: <https://arxiv.org/pdf/1707.06203.pdf>. Acessado em: 13 Jul. 2017.

WILLIAMS, M. H. Nutrition for Health, **Fitness and Sport**, 5th Edition. WeB/McGraw-Hill, New York, 1999.

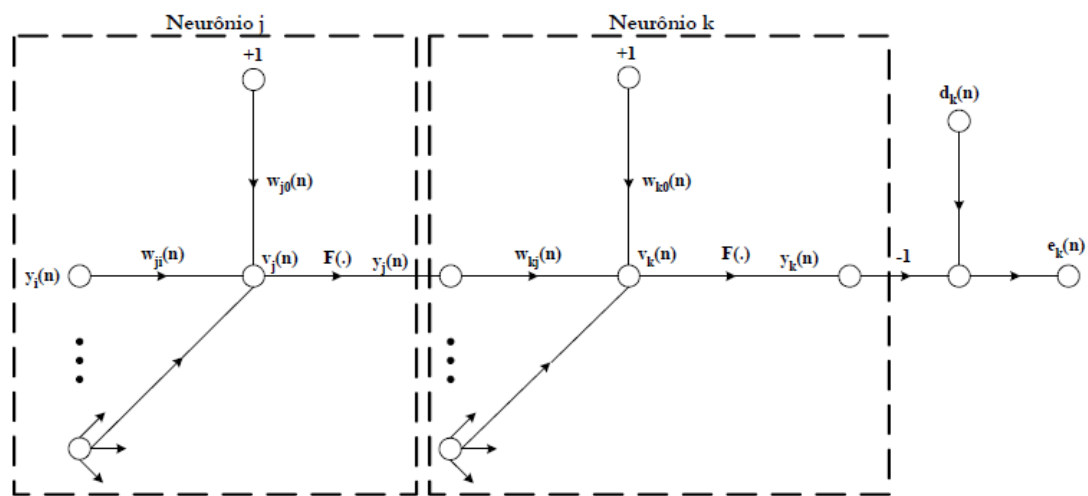
WILSON, S. M. Listening to speech activates motor áreas involved in speech procuction. **Nature Neuroscience**, v. 7, n. 7, p. 701 – 702, 2004.

YOON, S. W. et al. Vibration sensitivity of MEMS tuning fork gyroscopes. **IEEE Sensors Conference**, Atlanta, Georgia, USA, 2007.

## APÊNDICE A – Representação matemática do algoritmo de Retropropagação

Para o desenvolvimento matemático que dá suporte ao algoritmo de retropropagação, será considerado o exemplo da Figura A.1, que demonstra a interação durante a etapa de retropropagação entre o neurônio k da camada de saída, e o neurônio j da camada oculta. Através dessa derivação obteremos a representação matemática do valor do gradiente retropropagado (OLIVEIRA, 2005).

Figura A.1 – Grafo de orientação.



Fonte: (OLIVEIRA, 2005).

Em princípio;

$$\xi(w) = \frac{1}{2} \sum_{j=1}^U (d_j - y_j)^2 \quad (\text{A.1})$$

Onde  $\xi(w)$  é a função de erro e  $d_j$  e  $y_j$  são, respectivamente, a saída de referência e a saída obtida pela rede.

Através da utilização da regra de cadeia se calcula a derivada da função erro em relação a  $w$ ;

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = \frac{\partial \xi(n)}{\partial e_k(n)} \cdot \frac{\partial e_k(n)}{\partial y_k(n)} \cdot \frac{\partial y_k(n)}{\partial v_k(n)} \cdot \frac{\partial v_k(n)}{\partial w_{kj}(n)} \quad (\text{A.2})$$

Quando calculamos a primeira derivada do lado direito da Equação A.2, obtemos;

$$\frac{\partial \xi(n)}{\partial e_k(n)} = e_k(n) \quad (\text{A.3})$$

A segunda derivada do lado direito da Equação A.2 resulta em;

$$\frac{\partial e_k(n)}{\partial y_k(n)} = -1 \quad (\text{A.4})$$

A saída no neurônio  $k$  é dada por;

$$y_k = F_k(v_k(n)) \quad (\text{A.5})$$

A terceira derivada do lado direito da Equação A.2 pode ser igualada a Equação A.5, onde ' é a derivada de  $F$  em relação a  $v_k(n)$ ;

$$\frac{\partial y_k(n)}{\partial v_k(n)} = y_k = F'_k(v_k(n)) \quad (\text{A.6})$$

A partir do campo induzido pelo neurônio  $k$ ;

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) \cdot y_j(n) \quad (\text{A.7})$$

Obtemos a quarta derivada à direita da Equação A.2;

$$\frac{\partial v_k(n)}{\partial w_{kj}(n)} = y_j(n) \quad (\text{A.8})$$

Assim podemos reescrever a Equação A.2 da seguinte maneira;

$$\frac{\partial \xi(n)}{\partial w_{kj}(n)} = -e_k(n) \cdot F'_k(v_k(n)) \cdot y_j(n) \quad (\text{A.9})$$

Da Regra Delta temos que;

$$w_{kj}(n+1) = w_{kj}(n) - \Delta w_{kj}(n) \quad (\text{A.10})$$

Onde;

$$\Delta w_{kj}(n) = -\eta \cdot \frac{\partial \xi(n)}{\partial w_{kj}} \quad (\text{A.11})$$

Assim podemos reescrever a Equação A.2 da seguinte forma;

$$\Delta w_{kj} = \eta \cdot e_k(n) \cdot F'_k(v_k(n)) \cdot y_j(n) \quad (\text{A.12})$$

Definindo o gradiente  $\delta$  por;

$$\delta_k(n) = \frac{\partial \xi(n)}{\partial v_k(n)} \quad (\text{A.13})$$

Assim, pela regra da cadeia podemos acrescentar o seguinte termo a Equação A.13;

$$\delta_k(n) = \frac{\partial \xi(n)}{\partial y_k(n)} \cdot \frac{\partial y_k(n)}{\partial v_k(n)} \quad (\text{A.14})$$

Sendo que a segunda derivada do lado direito já foi calculada na Equação A.6.

A primeira derivada é calculada em função da camada a qual o neurônio pertence, se o esse for localizado na camada de saída, o valor da derivada, de acordo com a Equação A.1, será;

$$\frac{\partial \xi(n)}{\partial y_k(n)} = d_k(n) - y_k(n) \quad (\text{A.15})$$

Já que;

$$e_k(n) = d_k(n) - y_k(n) \quad (\text{A.16})$$

Então temos;

$$\delta_k(n) = e_k(n) \cdot F'_k(v_k(n)) \quad (\text{A.17})$$

Agora se o neurônio estiver em uma camada oculta, como o neurônio  $j$ , é compreendido que o sinal de erro que alimenta o neurônio  $j$  é gerado pela camada a frente, na direção da saída, portanto;

$$\xi(n) = \frac{1}{2} \sum_{k=1}^{ml} e_k^2(n) \quad (\text{A.18})$$

Onde  $\xi(n)$  é o erro de saída da rede e  $ml$  corresponde ao número de neurônios que constituem a camada de saída da rede.

Quando derivamos a Equação A.18 em relação ao neurônio  $j$  obtemos;

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_{k=1}^{ml} e_k(n) \cdot \frac{\partial e_k(n)}{\partial y_j(n)} \quad (\text{A.19})$$

Se aplicarmos a regra da cadeia na Equação A.19, obtemos;

$$\frac{\partial e_k(n)}{\partial y_j(n)} = \frac{\partial e_k(n)}{\partial v_k(n)} \cdot \frac{\partial v_k(n)}{\partial y_j(n)} \quad (\text{A.20})$$

Já que o índice  $k$  da Equação A.20 se refere à camada de saída da rede, e levando em conta a Equação A.16, obtemos;

$$\frac{\partial e_k(n)}{\partial v_k(n)} = F'_k(v_k(n)) \quad (\text{A.21})$$



Com o resultado da Equação A.7, obtemos a segunda derivada da Equação A.20, dada por;

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (\text{A.22})$$

Com o resultado das ultimas duas equações (Equações. A.21 e A.22) obtemos a seguinte expressão;

$$\frac{\partial e_k(n)}{\partial y_j(n)} = -F'_k(v_k(n)) \cdot w_{kj}(n) \quad (\text{A.23})$$

A derivada da função de custo em relação à saída do neurônio  $j$  é dada por;

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_{k=1}^{ml} e_k(n) \cdot F'_k(v_k(n)) \cdot w_{kj}(n) \quad (\text{A.24})$$

Se manipularmos a Equação A.14, que em parte se refere ao neurônio oculto da Equação A.24, obtemos;

$$\delta_j(n) = -\sum_{k=1}^{ml} e_k(n) \cdot F'_k(v_k(n)) \cdot w_{kj}(n) \cdot F'_j(v_j(n)) \quad (\text{A.25})$$

Manipulando as Equações A.25 e A.17 obtemos a representação do valor do gradiente para o neurônio oculto  $j$  através da seguinte expressão;

$$\delta_j(n) = F'_j(v_j(n)) \sum_{k=1}^{ml} \delta_k(n) \cdot w_{kj}(n) \quad (\text{A.26})$$

APÊNDICE B – Código (C) utilizado para a geração dos sinais artificiais.

```
#include <stdio.h>
```

```
#include <stdlib.h>
```

```
// Aproximação por MA(2)
```

```
int nolieA[82] = {  
    0, 0, 0, 0, 0, 35, 35, 7, 38, -10, 40, 47, 5, -4, 181,  
    140, 249, 393, 340, -263, -752, -890, -573, -840, -42,  
    -66, -21, -16, -127, -289, -90, -55, 78, 388, 223, 357,  
    381, 261, 331, 302, 307, 221, 251, 214, 198, 147, 108,  
    106, 92, 52, 27, 35, 24, -67, -35, -163, -94, -163, -180,  
    -101, -100, -1699, -44, -2012, -3337, 963, 385, 25, 11,  
    102, 396, 541, 615, -26, -187, -309, -289, -145, -13,  
    19, 4, -63  
};
```

```
int nolieB[82] = {  
    32, 29, -53, 64, 62, 41, 63, 91, 66, 47, -22, -25, 46,  
    -98, 23, 178, 298, 288, 336, 256, -265, -677, -1055,  
    -799, -522, 376, 260, 122, 468, -990, 284, -101, 174,  
    246, 328, 280, 227, 244, 288, 275, 257, 184, 217, 143,  
    71, 46, 69, 50, 45, 58, 27, 21, 52, 36, 14, 0, 21, 40,  
    68, 125, 99, 94, -5, -1360, -1746, -930, -96, -560,  
    -340, 428, 15, 575, 576, 82, -162, -147, -42, -48, -119,  
    -47, -48, -56  
};
```

```
int acelerometro[82], acel2[82], acel3[82];
```

**// Gera um número randômico com distribuição gaussiana de intervalo -x até +x**

```
int gauss(int x)
{
    int i, soma=0;
    if(x > 0)
    {
        for(i=0; i<6; i++) soma = soma + (rand() % x);
        for(i=0; i<6; i++) soma = soma - (rand() % x);
        if(soma > x) soma = x;
        if(soma < -x) soma = -x;
    }
    return soma;
}
```

**// Gera um número randômico entre 0...x-1**

```
int random(int x)
{
    if (x > 0) return (rand() % x); else return x;
}
```

**// Inicializa o vetor de aceleração com uma distribuição gaussiana.**

```
void inicializa(int k)
{
    int i;
    for(i=0; i<82; i++)
        acelerometro[i] = gauss(k);
}
```

**// Depois de preenchidos os parâmetros verifica se os pontos estão dentro do intervalo +16G e -16G.**

**// Caso contrário o sinal é saturado.**

```
void inspeciona(void)
{
    int i;
    for(i=0; i<82; i++)
    {
        if(accelerometro[i] > 4000) acelerometro[i] = 4000;
        if(accelerometro[i] < -4000) acelerometro[i] = -4000;
    }
}
```

**// Gera uma função triângulo genérica.**

```
void triang(int a, int t1, int t2, int t3, int da, int dt1, int dt2, int dt3, int nr)
{
    int T1, T2, T3, A, i;
    float r, s;
```

**// Calcula os intervalos.**

```
T2 = t2 + gauss(dt2);
T1 = T2 - (t2-t1) - random(dt1);
T3 = T2 + (t3-t2) + random(dt3);
A = a + gauss(da);
```

**// Calcula a derivada positiva.**

```
s = T2-T1;
for(i=T1; i<T2; i++)
{
    r = (i-T1);
    acelerometro[i] = acelerometro[i] + (A*r/s);
}
```

**// Calcula a derivada negativa.**

```

s = T2-T3;
for(i=T2; i<T3; i++)
{
    r = (i-T3);
    acelerometro[i] = acelerometro[i] + (A*r/s);
}

// Acrescenta ruuido.

for(i=T1; i<=T3; i++) acelerometro[i] = acelerometro[i] + gauss(nr);
}

/int main(void)
{
    FILE *f;
    char fname[100] = "NOLIE.csv";
    int i;
    printf("Ande de skate\n");
    // Inicializando gerador numeros aleatórios...
    srand(time(NULL));
    // Andando de skate...
    inicializa(45);
    triang(450, 14, 18, 20, 45, 0, 0, 0, 20);
    triang(-1000, 20, 22, 24, 100, 0, 0, 0, 25);
    triang(-800, 23, 24, 25, 80, 0, 0, 0, 25);
    triang(-300, 28, 30, 32, 30, 0, 0, 0, 15);
    triang(450, 32, 34, 60, 45, 0, 0, 0, 15);
    triang(-3500, 61, 62, 63, 170, 0, 0, 0, 30);
    triang(-1700, 63, 65, 66, 350, 0, 0, 0, 40);
    triang(1000, 66, 67, 68, 100, 0, 0, 0, 20);
    triang(650, 68, 73, 74, 65, 0, 0, 0, 15);

```

```
triang(-300, 74, 76, 80, 30, 0, 0, 0, 10);
inspecciona();
for(i=0; i<82; i++) acel2[i] = acelerometro[i];
inicializa(40);
triang(450, 14, 18, 20, 45, 1, 1, 1, 20);
triang(-800, 20, 22, 24, 100, 1, 1, 1, 25);
triang(-1100, 23, 24, 25, 80, 0, 2, 0, 25);
triang(-300, 28, 30, 32, 30, 0, 2, 0, 15);
triang(450, 32, 34, 60, 45, 0, 2, 4, 15);
triang(-2500, 61, 62, 63, 170, 0, 1, 0, 30);
triang(-3800, 63, 65, 66, 350, 0, 1, 0, 40);
triang(600, 66, 67, 68, 100, 0, 1, 0, 20);
triang(1100, 68, 73, 74, 65, 0, 1, 0, 15);
triang(-300, 74, 76, 80, 30, 0, 0, 0, 10);
inspecciona();
for(i=0; i<82; i++) acel3[i] = acelerometro[i];
inicializa(40);
triang(450, 14, 18, 20, 0, 0, 0, 0, 20);
triang(-1000, 20, 22, 24, 0, 0, 0, 0, 25);
triang(-800, 23, 24, 25, 0, 0, 0, 0, 25);
triang(-300, 28, 30, 32, 0, 0, 0, 0, 15);
triang(450, 32, 34, 60, 0, 0, 0, 0, 15);
triang(-1700, 61, 62, 63, 0, 0, 0, 0, 30);
triang(-3500, 63, 65, 66, 0, 0, 0, 0, 40);
triang(1000, 66, 67, 68, 0, 0, 0, 0, 20);
triang(650, 68, 73, 74, 0, 0, 0, 0, 15);
triang(-300, 74, 76, 80, 0, 0, 0, 0, 10);
inspecciona();
```

```
// Salvando os dados coletados (artificiais)  
f = fopen(fname, "w");  
if(f != NULL)  
{  
    for(i=0; i<82; i++)  
        fprintf(f, "%d; %d; %d; %d; %d\n", nolieA[i], nolieB[i], acel2[i], acel3[i],  
acelerometro[i]);  
    fclose(f);  
}  
printf("Pare de andar de skate\n");  
system("PAUSE");  
return 0;  
}
```



Pontifícia Universidade Católica do Rio Grande do Sul  
Pró-Reitoria Acadêmica  
Av. Ipiranga, 6681 - Prédio 1 - 3º andar  
Porto Alegre - RS - Brasil  
Fone: (51) 3320-3500 - Fax: (51) 3339-1564  
E-mail: [proacad@pucrs.br](mailto:proacad@pucrs.br)  
Site: [www.pucrs.br/proacad](http://www.pucrs.br/proacad)