

Aplicação de Inteligência Computacional como Ferramenta de Apoio para Análise de Risco de Queda em Idosos

Luan M. M. Pereira*. Daniele Alves da Silva.** Laiana S. de A. Mesquita.*
Nayra F. L. C. Branco.*** Hermes M. G. C. Branco.** Guilherme Alencar Barreto.****

* Universidade Estadual do Piauí (e-mail: luanpereira@aluno.uespi.br, laianasepulveda@hotmail.com)

** Universidade Federal do Piauí (e-mail: danielealves17@hotmail.com, hermescb@ufpi.br)

*** Centro Universitário do Piauí (e-mail: nayraferreiralima@gmail.com)

**** Universidade Federal do Ceará (e-mail: gbarreto@ufc.br)

Abstract: Fall is a serious public health problem, especially in the elderly, and several approaches based on sensors and the use of computational intelligence to classify the risk of falling in the elderly have been proposed in the literature. This work used inertial sensors (accelerometer and gyroscope), signal processing techniques and computational intelligence to estimate the score that elderly people would obtain with the application of the Timed Up and Go (TUG) and Berg balance scales. The results of the proposed approach proved to be promising, with a correlation between the real and estimated scores near to 1 for the best models.

Resumo: A queda é um grave problema de saúde pública, principalmente em idosos, e diversas abordagens baseadas em sensores e em uso de inteligência computacional para classificação de risco de queda em idosos vêm sendo propostas na literatura. Este trabalho utilizou sensores inerciais (acelerômetro e giroscópio), técnicas de processamento de sinais e de inteligência computacional para estimar a pontuação que idosos obteriam com a aplicação das escalas de equilíbrio Timed Up and Go (TUG) e Berg. Os resultados da abordagem proposta mostraram-se promissores, com uma correlação entre as pontuações reais e as estimadas próxima a 1 para os melhores modelos.

Keywords: Fall Risk; Elderly; Neural Network; PMC; SVM; TUG Test; Berg Test.

Palavras-chaves: Risco de Queda; Idosos; Redes Neurais; PMC; SVM; Teste TUG; Teste Berg.

1. INTRODUÇÃO

Segundo a Organização Mundial da Saúde (OMS), considera-se idoso todo indivíduo com 60 anos ou mais. O Brasil possui cerca de 28 milhões de idosos, número que representa 13% da população de todo, segundo a projeção da população divulgada em 2018 pelo IBGE. Belasco e Okuno (2019) apontam que, de acordo com dados de 2018, 39,2% dos idosos com idade acima de 75 anos apresentam dificuldade na capacidade de realizar as Atividades de Vida Diária (AVDs), o que pode ser reflexo da alta taxa de prevalência de doenças crônicas entre os idosos. Neste cenário, quedas associadas a outros fatores como declínio cognitivo, mostram-se como um grande fator contribuinte para este número, que chega a ser um terço da população idosa (DA CRUZ, 2015; DE BARROS et al, 2015).

Diante da gravidade do problema apresentado, da necessidade de garantir boa qualidade de vida aos idosos e de diminuir os custos com cuidados de saúde (CARVALHO et al, 2011), identificar os fatores de risco (intrínsecos e extrínsecos) de quedas é essencial para a prevenção deste agravo, pois possibilita planejar estratégias de prevenção, reorganização ambiental e de reabilitação funcional (ALMEIDA et al, 2012; CRUZ et al, 2012). Os fatores intrínsecos estão relacionados ao próprio sujeito, o qual pode apresentar: redução da função

dos sistemas que compõem o controle postural, doenças, transtornos cognitivos e comportamentais, incapacidade em manter ou para recuperar o equilíbrio, faixa etária mais elevada; autopercepção ruim da visão e autopercepção ruim da saúde, a alteração de marcha, a debilidade muscular e a incapacidade para as atividades básicas de vida diária (ABVD) e para as atividades instrumentais de vida diária (AIVD) (ALMEIDA et al, 2012; DELLROZA et al, 2014).

Para a avaliação de fatores intrínsecos, os profissionais de saúde utilizam-se de alguns testes e escalas de avaliação, como, por exemplo, o Timed Up and Go Test (TUG Test) para a mobilidade funcional envolvendo velocidade, agilidade e equilíbrio dinâmico das pessoas idosas (DE SOUSA et al, 2019), e a Escala de Equilíbrio de Berg, para avaliar o equilíbrio estático e dinâmico dos idosos (ANDRADE et al, 2019). Tais avaliações são feitas de forma visual e sem recursos de automatização por parte dos profissionais de saúde, sendo seus resultados, muitas vezes, altamente dependentes da experiência do profissional que aplica e sujeitos a outros erros comuns a procedimentos realizados de forma manual, como por exemplo erros de medidas. A utilização de sensores e de ferramentas de Inteligência Computacional pode contribuir para a avaliação de equilíbrio de idosos, como uma ferramenta auxiliar no processo. Vários

trabalhos seguem esta linha, e empregam sensores inerciais e ferramentas de inteligência computacional para classificar os idosos quanto ao risco de quedas, tendo como padrão ouro a classificação obtida por uma escala tradicional (CABY et al, 2011; HOWCROFT et al, 2017).

Apesar de muito utilizadas por profissionais de saúde na prática clínica como instrumento de predição do risco de quedas, as escalas de avaliação, por vezes, são questionadas quanto a sua real eficiência (OLIVER, 2008; ANSAI et al, 2014). Os estudos em (GREENE et al, 2010, 2012; MARSCHOLLEK et al, 2011), alcançaram resultados satisfatórios utilizando modelos de Logistic Regression (LR) (GREENE et al, 2010, 2012) e Support Vector Machine (SVM) para classificar idosos caidores (MARSCHOLLEK et al, 2011) baseados em dados extraídos de sensores inerciais fixados ao corpo dos participantes. Nos trabalhos reportados, as ferramentas de Inteligência computacional obtiveram um desempenho melhor que o das escalas tradicionais para identificar caidores quando os resultados obtidos foram comparados com o histórico de quedas dos participantes. Contudo, avaliação de um especialista é indispensável para apontar o risco de queda de um idoso.

Este trabalho propõe uma abordagem que permita estimar o tempo utilizado por um voluntário para realizar o TUG Test e a pontuação obtida na Escala de Equilíbrio de Berg, dispondo de dados obtidos a partir de sensores inerciais (acelerômetro e giroscópio) dos voluntários. Fornecer uma estimativa das pontuações, em vez de uma classificação direta do idoso quanto ao risco de queda, pode ajudar os profissionais na tomada de decisão de uma forma mais efetiva, pois geralmente as notas de corte das diversas escalas podem variar conforme as características da população analisada. Para a fornecer a estimativa das pontuações nas escalas foram empregadas duas ferramentas uma rede Perceptron Multi Camadas (PMC) e uma Regressão por Vetor de Suporte (SVR). O restante do artigo está organizado nas seguintes seções: 2 Metodologia; 3 Resultados; 4 Conclusões.

2. METODOLOGIA

Nesta seção descreve-se o processo de aquisição de dados, as ferramentas de extração de características e de inteligência computacional utilizadas, além dos métodos empregados para teste e validação da abordagem proposta.

2.1 Dispositivos de Aquisição de Dados e Servidor de Aplicação

O protótipo de coleta de dados projetado possuía um sensor GY-80 que contém um sensor acelerômetro ADLX345 e um sensor giroscópio L3G4200D. Os dados foram coletados a uma taxa de 125 Hz, suficiente para amostrar o sinal a ser monitorado. Cabe destacar que a taxa adotada neste trabalho é superior à adotada em outros trabalhos da literatura correlata (LI, 2009; JUNIOR e ADAMI, 2018). Um BeagleBone foi empregado como servidor de aplicação e broker para comunicação MQTT. O cenário é composto de uma rede de área local (LAN), um servidor Django, um servidor MQTT para aplicação do avaliador (pessoa responsável por monitorar

o voluntário) e comunicação dos dispositivos de coleta de dados. A Figura 1 apresenta registro fotográfico do protótipo e os principais componentes da arquitetura empregada.

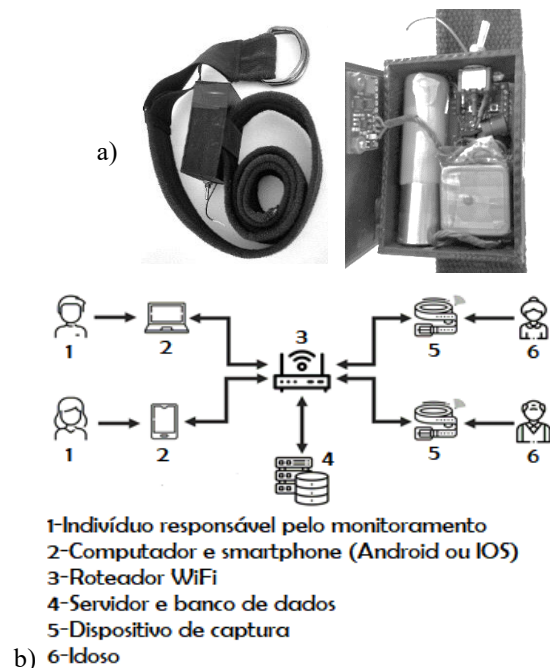


Figura 1. a) dispositivo de coleta de dados. b) Cenário de coleta de dados.

2.2 Coleta de Dados

A amostra analisada consiste dos dados de 32 voluntários com idade média de $69,46 \text{ anos} \pm 5,31$, com 18 voluntários do sexo feminino e 14 do sexo masculino. A altura média dos participantes foi de $153,09 \text{ cm} \pm 9,25$ e o peso médio foi de $62,53 \pm 7,89$. Dos idosos participantes, 7 foram apontados como com risco de quedas seguindo critérios da EEB, enquanto 25 foram apontados como tendo baixo risco. Segundo o critério do TUG Test, 6 voluntários foram apontados como tendo alto risco de quedas.

O Timed Up and Go Test (TUG Test) foi realizado para avaliar a mobilidade e o equilíbrio funcional. No teste o participante realizou a tarefa de levantar de uma cadeira caminhar 3 metros, virar, voltar para a cadeira e se sentar novamente. O idoso partiu da posição inicial com as costas apoiadas na cadeira. A cronometragem iniciou depois do sinal de partida e parou somente quando o idoso se colocou novamente na posição inicial. O resultado do teste em até 10 segundos é considerado normal para idosos saudáveis, independentes e sem risco de quedas; entre 11-20 segundos é o esperado para idosos com deficiência ou frágeis, com independência parcial e com médio risco de quedas; tempo maior ou igual a 20 segundos sugere que o idoso apresenta déficit importante da mobilidade física e elevado risco de quedas (VALDUGA et al, 2016). Outros critérios podem ser utilizados para os cortes, dependendo da população a ser estudada, por exemplo, em SHUMWAY-COOK et al (2000), tempo $<13,5s$ para idosos sem risco de quedas e tempo $>13,5s$ para idosos com. Este teste foi realizado com os voluntários utilizando a cinta com sensores inerciais colocada na altura da vértebra L3.

A Escala de Equilíbrio de Berg (EEB) possui 14 itens, sendo que cada item vale de 0 a 4 pontos, com escore total de 56 pontos resultando em nenhuma alteração de equilíbrio, enquanto menor a pontuação obtida maior será o risco de queda. Escores menores ou iguais a 45 serão considerados como risco de queda (FERRARESI et al, 2015). Cabe destacar que outros estudos também apontam cortes diferentes para a EEB, dependendo da população estudada, por exemplo em BLUM et al (2008) uma pontuação menor que 40 aponta alto risco de quedas. As 14 tarefas listadas na EEB são as seguintes: levantar-se de uma cadeira; permanecer em pé sem apoio; permanecer sentado sem apoio no dorso; sentar-se na cadeira; transferir-se de uma cadeira para a outra; permanecer em pé com os olhos fechados; permanecer em pé com os pés juntos; alcançar a frente permanecendo em pé (também chamado de Teste do Alcance Funcional); pegar um objeto no chão; virar-se e olhar para trás; girar 360 graus; posicionar os pés alternadamente em um degrau; permanecer em pé com um pé na frente do outro; permanecer em pé sobre uma perna. Além da capacidade de realizar a atividade, foi contabilizado o tempo de permanência que varia de 3 segundos a 2 minutos, além da quantidade de repetições necessárias para realizar a atividade (FERRARESI et al, 2015).

O Teste do Alcance Funcional (TAF) foi realizado com idoso utilizando a cinta com sensores inerciais. Este teste determina o quanto o idoso é capaz de se deslocar anteriormente. Uma fita métrica foi colocada na parede, paralela ao chão, e posicionada na altura do acrômio do voluntário. O idoso descalço foi posicionado com os pés confortáveis e paralelos entre si, perpendicularmente em relação à parede e próximo ao início da fita métrica. Com punhos em posição neutra, cotovelos estendidos e ombro fletidos a 90°, o participante foi instruído a realizar a inclinação para frente sem tocar na fita e, em seguida, retornar para posição inicial para ser verificado o deslocamento sobre ela. Deslocamentos menores que 15 cm indicam fragilidade do voluntário e risco de quedas (KARUKA et al, 2011). Os itens da EEB de permanecer em pé sem apoio com olhos abertos (TOA), permanecer em pé sem apoio com olhos fechados durante 1 minuto (TOF), e virar-se e olhar para trás (TOT) também foram realizados com voluntário também utilizando a cinta com sensores inerciais. As demais tarefas da EEB foram realizadas sem uso da cinta, apenas para contabilizar a pontuação total do voluntário conforme EEB.

2.3 Extração de Características

Neste trabalho, dividiu-se o processo de extração de características em duas partes, processamento de sinais no domínio do tempo, e processamento de sinais no domínio da frequência, onde tal metodologia foi adotada de forma empírica. As características no domínio do tempo utilizadas estão descritas na Tabela 1.

Cabe destacar que cada um dos parâmetros do domínio do tempo foi obtido para os sinais dos 3 eixos (x, y, z) e para o sinal resultante tanto do acelerômetro quanto do giroscópio no domínio da frequência, todos os parâmetros foram extraídos a partir de uma transformação dos dados o utilizando a Transformada de Fourier de Tempo Discreto (DTFT), os sinais

dos 3 eixos (x, y, z) e para o sinal resultante tanto do acelerômetro quanto do giroscópio. A Tabela 2 apresenta os parâmetros no domínio da frequência.

Tabela 1. Parâmetros utilizados no domínio do tempo.

Parâmetros	Descrição
Maior pico do sinal	Indica se houve níveis elevados de aceleração, além de servir como gatilho para utilização do processamento por rede neural.
Maior vale	Indica se houve níveis elevados de aceleração no sentido oposto à referência, além de servir como gatilho para utilização do processamento por rede neural.
Quantidade de picos por janela de tempo (velocidade)	Indica alterações na velocidade da macha.
Mediana	Valor mediano do sinal.
Média	Valor médio do sinal.
Valor RMS	Descrito pela seguinte expressão: $x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$
Desvio padrão	Indica quão disperso é um sinal em relação a sua média.
Variância	Indica quão disperso é um sinal em relação a sua média

Tabela 2. Parâmetros utilizados no domínio da frequência.

Parâmetros	Descrição
10 Frequências de pico	Indica em quais frequências ocorreram os 10 maiores valores do módulo do sinal no domínio da frequência.
Centroide espectral	Indica o centro de massa do espectro de um sinal, é dado em Hz e calculado ela seguinte fórmula: $c = \frac{\sum_{n=1}^{N-1} F(n) f(n)}{\sum_{n=1}^{N-1} F(n) } \quad (2)$ em que F(n) é o módulo do sinal complexo.
Média ponderada das 10 maiores frequência	Indica o centro massa do espectro considerando apenas as 10 primeiras frequências de pico, logo é dado pela mesma fórmula do centroide espectral.
Densidade espectral de potência média	Indica a quantidade potência por unidade de banda em função da frequência de um sinal. Pode ser calculado a partir do periodograma de um sinal. $PSD = \frac{1}{N} \sum_{i=1}^N f_i \cdot F(f_i) \quad (3)$ sendo F(fi) o periodograma do sinal.

2.4 Ferramentas de Inteligência Computacional Utilizadas

Na abordagem proposta as características extraídas dos sinais obtidos foram submetidas a uma rede Perceptron Multicamadas (PMC) e a uma Support Vector Regression (SVR) para estimação da pontuação obtida na EEB e tempo no TUGTest.

A PMC proposta neste trabalho possui somente uma camada oculta com 100 neurônios, sendo a função Relu utilizada como de função de ativação na camada oculta, e função identidade utilizada na camada de saída contendo apenas 1 neurônio. A taxa de aprendizado adotada durante o treinamento foi de 0,001 com um total de 100000 iterações utilizando o algoritmo de treinamento backPropagation.

A SVR empregada possui o kernel linear e um parâmetro de regularização $C = 20$, e o critério de parada foi definido como o término de 100000 iterações ou até a variação do erro seja inferior a 10^{-10} . Em um primeiro momento as redes foram treinadas com todas as variáveis disponíveis para cada experimento.

Em um segundo momento realizou-se uma seleção de atributos dispondo de um algoritmo de Regressão com Árvore de Decisão. Para a implementação de todas as ferramentas citadas nesta seção utilizou-se a biblioteca sklearn que é uma ferramenta simples e eficiente para análise preditiva de dados construída a partir de outras bibliotecas como numpy, Scipy e matplotlib, todas desenvolvidas através da linguagem python.

2.5 Experimentos

Neste trabalho aplicou-se o algoritmo de validação cruzada K-fold (com $K=4$, $K=8$, $K=16$ e $K=32$). Assim os dados de entrada foram divididos em 4, 8, 16 e 32 grupos. Cabe observar que quando temos o $K=32$ estamos aplicando o método chamado Leave One Out, recomendado para situações em que o banco de dados possui poucas instâncias para treinamento e teste. Foram realizados 3 experimentos, definidos a partir da fonte das entradas das redes. Para cada experimento foram realizadas algumas variações.

No primeiro experimento tomou-se como entradas características de sinais obtidos durante a realização do TUG Teste e as redes foram treinadas para estimar o tempo do TUG Test (a saída fornecida para treinamento foi o tempo do TUG Test). A seguir, ainda com as entradas referentes aos sinais obtidos durante a realização do TUG Test, as redes foram treinadas para estimar a pontuação total obtida com a aplicação da EEB, logo, nesse caso, a saída fornecida para a rede foi a pontuação total de cada voluntário obtida durante a aplicação das 14 atividades da EEB.

No segundo experimento, utilizou-se como dados de entrada para as redes as características dos sinais obtidos durante as 4 atividades da EEB, realizadas pelos voluntários enquanto usavam a cinta com sensores inerciais. As redes foram treinadas primeiro para estimar o tempo do TUG Test e em seguida para estimar a pontuação completa obtida com a realização das 14 atividades da EEB.

Por fim, no terceiro experimento, foram fornecidas como entradas para as redes as características dos sinais obtidos durante a realização do TUG Test e das 4 atividades da EEB. Novamente primeiro estimou-se o tempo do TUG Test e em seguida a pontuação completa da EEB. Em todas as situações manteve-se fixa a parametrização das redes descritas no tópico 2.4, variando-se apenas o número de entradas para cada experimento. No primeiro experimento as redes possuíam 60 características de entrada; no segundo experimento 240, e no terceiro 300. Após a realização dos experimentos sem seleção de atributos, todos os experimentos foram repetidos realizando-se uma seleção de atributos, determinando os 5 melhores parâmetros de entrada para cada rede.

3. RESULTADOS

Após finalizar os experimentos conforme descrito no tópico 2.5, obteve-se os resultados apresentados nas Tabelas 3, 4, respectivamente para os testes com 4 e 32 partições do conjunto de dados. Após uma análise das duas tabelas percebe-se que os resultados obtidos seguem o mesmo padrão, independentemente da quantidade de partições utilizadas no processo de treinamento, portanto os resultados serão discutidos em conjunto. Os resultados obtidos para 8 e 16 partições foram muito similares aos obtidos para 4 e 32 partições, portanto não serão apresentados

Percebe-se que, independentemente da origem dos sinais utilizados (do TUG Test, EEB ou ambos), os erros obtidos com o uso da SVR foram menores quando foram utilizadas como entrada todas as características disponíveis. Quando do uso da SVR a estimativa de tempo do TUG Test e dos pontos da EEB sem seleção de atributos foram baixos, com erro médio menor que uma unidade de medida. Quando se utilizou a SVR e os dados de entrada foram características de sinais obtidos durante a realização de atividades da EEB, os resultados foram ainda melhores, com erro médio abaixo de 10^{-1} , tanto para a estimativa do tempo do TUG Test quanto da pontuação da EEB. Quando o vetor de entrada foi formado por todas as características extraídas dos dois sinais, os resultados foram muito próximos aos obtidos quando a fonte dos sinais são apenas as atividades da EEB. Ainda é possível notar que a correlação entre os valores reais obtidos com a aplicação das escalas e o valor estimado pela SVR sempre foi muito próximo a 1 para os casos em que não foi realizada a seleção de atributos.

Quando o algoritmo utilizado foi a rede PMC, os resultados fornecidos pelas redes que tiveram como entradas todas as características dos sinais obtidos durante as quatro atividades da EEB monitoradas com os sensores, não foram satisfatórios. Isso também foi observado para as redes que tinham como entrada características obtidas tanto dos sinais do TUG Test quanto dos sinais das atividades da EEB, quando não foi realizada seleção de atributos. Já as redes PMC que tinham como entradas apenas 5 características selecionadas dos sinais obtidos das mesmas fontes citadas anteriormente, apresentaram uma resposta muito boa, com erro médio menor que 1. Esta observação sugere que as redes PMC apresentam dificuldade de lidar com a grande quantidade de entradas fornecidas quando não foi realizada a seleção de atributos.

Por outro lado, quando as características utilizadas como entradas da PMC foram extraídas dos sinais obtidos durante o TUG Test, a PMC apresentou o melhor resultado nos experimentos para a rede em que não foi realizada seleção de atributos. Apesar de possuir 60 entradas, um valor relativamente alto quando comparado aos testes realizados com seleção de atributos (5 entradas), este valor é consideravelmente menor que a quantidade de entradas das outras topologias testadas de PMC sem seleção de atributos, com 240 e 300 entradas, o que pode ter contribuído para a obtenção do melhor resultado pela PMC sem seleção de atributos com dados obtidos com TUG Test.

Em resumo, é possível afirmar que tanto as SVRs quanto as PMCs propostas podem estimar com precisão o tempo de TUG Test e os pontos obtidos na EEB pelos voluntários, dispondo de características dos sinais fornecidos por sensores inerciais durante a realização tanto de um quanto do outro teste de equilíbrio. No entanto, as PMCs testadas, na maioria das vezes, obtiveram um melhor desempenho quando auxiliadas por uma

ferramenta de seleção de atributos. Já as SVR apresentaram melhores resultados utilizando todas as características disponíveis dos sinais.

A Tabela 5 apresenta os melhores atributos extraídos, com base no tipo de entrada e tipo de saída, obedecendo a seguinte nomenclatura: [nome do atributo (sinal do acelerômetro - indicado pela letra *a* - ou giroscópio - indicado pela letra *g* - seguido do seu respectivo eixo, sigla da atividade)]. Percebe-se que o TAF e o TOT foram aqueles, dentre as 4 atividades da EEB realizadas com os sensores, cujos sinais mais forneceram características selecionadas, indicando que os dois, em conjunto com o TUG Test, são relevantes para a avaliação do equilíbrio pela metodologia proposta.

Já a Figura 2 apresenta uma estimativa, através do algoritmo PMC, do tempo utilizado para realizar o teste TUG e da pontuação adquirida no teste BERG respectivamente através dos dados de entrada TUG com a validação K=32 e sem seleção de atributos.

Tabela 3. Resultados dos experimentos com K=4.

Algoritmo	Tipo de entrada	Tipo de saída	Erro absoluto médio da pontuação estimada pelos modelos		Correlação entre as pontuações estimadas pelos modelos e as obtidas com uso das escalas tradicionais	
			Sem seleção de atributos	Com seleção de atributos	Sem seleção de atributos	Com seleção de atributos
PMC	TUG	TUG	0,0004s	0,0357s	1,0000	0,9999
		BERG	0,0003	0,1193	1,0000	0,9991
	BERG	TUG	4,1743s	0,2163s	-0,0336	0,9891
		BERG	1,6912	0,1120	0,8184	0,9984
	TUG+ BERG	TUG	4,5303s	0,1840s	-0,3096	0,9941
		BERG	5,9812	0,0772	0,2137	0,9997
SVR	TUG	TUG	0,1567s	1,2900s	0,9978	0,9162
		BERG	0,4998	3,0649	0,9820	0,6648
	BERG	TUG	0,0986s	2,3287s	0,9997	0,5908
		BERG	0,0978	2,1998	0,9999	0,7820
	TUG+ BERG	TUG	0,0959s	1,3798s	0,9998	0,9016
		BERG	0,0978	2,3194	0,9999	0,7625

Tabela 4. Resultados dos experimentos com K = 32.

Algoritmo	Tipo de entrada	Tipo de saída	Erro absoluto médio da pontuação estimada pelos modelos		Correlação entre as pontuações estimadas pelos modelos e as obtidas com uso das escalas tradicionais	
			Sem seleção de atributos	Com seleção de atributos	Sem seleção de atributos	Com seleção de atributos
PMC	TUG	TUG	0,0006s	0,0497s	1,0000	0,9998
		BERG	0,0006	0,3585	1,0000	0,9916
	BERG	TUG	4,1597s	0,1080s	-0,0304	0,9981
		BERG	3,1865	0,1515	0,6756	0,9978
	TUG+ BERG	TUG	4,5451s	0,0662s	-0,3640	0,9996
		BERG	6,0441	0,1735	0,2027	0,9986
SVR	TUG	TUG	0,1567s	1,2900s	0,9978	0,9162
		BERG	0,4998	3,0649	0,9820	0,6648
	BERG	TUG	0,0986s	2,3287s	0,9997	0,5908
		BERG	0,0978	2,1998	0,9999	0,7820
	TUG+ BERG	TUG	0,0959s	1,3798s	0,9998	0,9016
		BERG	0,0978	2,3194	0,9999	0,7625

Tabela 5. Atributos selecionados.

Tipo de entrada	Tipo de saída para predição	Atributos selecionados
TUG	TUG	Valor rms (gx, TUG Test), Psd (gx, TUG Test), Maior pico (az, TUG Test), Desvio padrão (az, TUG Test), Desvio padrão (gx, TUG Test)
	BERG	Maior pico (gx, TUG Test), Psd (gx, TUG Test), Psd (gy, TUG Test), Velocidade (ax, TUG Test), Velocidade (ay, TUG Test)
BERG	TUG	Desvio padrão (gy, TAF), Média ponderada das 10 maiores frequência de pico (az, TAF), Maior vale (az, TOT), Variância (gx, TAF), Maior pico (ay TOT)
	BERG	Valor rms (ay, TAF), Maior pico (gz, TOT), Desvio padrão (gy, TAF), Valor rms (gx, TOA), Valor rms (gx, TOT)
TUG+BERG	TUG	Valor rms (gx, TUG Test), Maior pico (gz, TOT), Variância (gx, TOT), Desvio padrão (gx, TUG Test), Psd (gx, TOT)
	BERG	Valor rms (ay, TAF), Valor rms (az, TAF), Variância (gy, TAF), Valor rms (gx, TOA), Valor rms (ax, TUG Test)

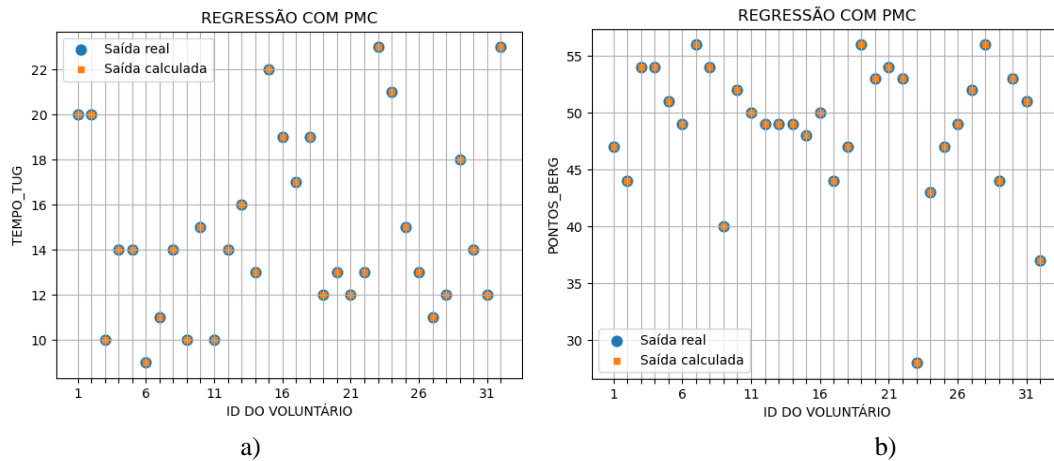


Figura 2. a) Regressão com PMC para estimação do tempo de teste TUG usando como entrada características obtidas a partir dos sinais dos sensores inerciais durante a realização do TUG Teste; b) Regressão com PMC para estimação da pontuação de teste BERG usando como entrada características obtidas a partir dos sinais dos sensores inerciais durante a realização do TUG Teste.

É importante que a avaliação do risco de queda do idoso seja a mais segura e eficiente possível, mas, ao mesmo tempo, deve ser realizada de forma rápida, com poucas atividades e sem gerar incômodos aos idosos, utilizando o mínimo de dispositivos de registro de dados. Nesse sentido a realização do TUG Test com o sensor, como proposto neste trabalho, se mostra como uma boa alternativa, assim como a utilização da EEB de forma reduzida, com 4 atividades, dispondo dos sensores inerciais. Nos nossos experimentos encontramos um modelo que permite estimar a pontuação que um voluntário obteria na EEB com erro médio de entre 4×10^{-4} e 6×10^{-4} , dependendo do número de partições utilizadas na validação cruzada, dispondo de uma PMC e de dados coletados com sensores inerciais durante a realização do TUG Test (Modelo PMC T-B S/EC). Outro modelo, que utiliza uma SVR e dados coletados pelos sensores durante a realização de apenas 4 atividades da EEB, permitiu estimar a pontuação total, da EEB que tem por base 14 atividades, com um erro médio de 9×10^{-2} (Modelo SVR B-B S/EC). Outro modelo com SVR, que também utiliza características dos sinais das 4 atividades da

EEB, permitiu estimar o tempo do TUG Test com um erro médio de 9×10^{-2} (Modelo SVR B-T S/EC). Caso seja necessário trabalhar com os modelos de aprendizagem de máquinas dispondo de poucos atributos, destaca-se o desempenho da PMC que tem como entrada 5 características selecionadas dos sinais das 4 atividades da EEB, que permitiu estimar o tempo do TUG Test com um erro médio de 1×10^{-1} (Modelo PMC B-T C/EC), enquanto outro modelo PMC que possui como entrada características selecionadas dos sinais obtidos durante a EEB, fornece estimativa da pontuação obtida nas 14 atividades com um erro médio de 1×10^{-1} (Modelo PMC B-B C/EC). Dentre todos os experimentos realizados, estes cinco modelos se mostraram os mais adequados, pois permitem que um especialista tenha a estimativa do desempenho de um idoso em 2 escalas, a partir da realização de apenas um teste simples, o TUG Test, ou com a realização de apenas 4 atividades da EEB.

A abordagem apresentada neste artigo fornece as notas em cada uma das escalas e o especialista classifica o idoso quanto ao risco de queda. Considerando os valores estimados para o

Tempo do Tug Test, bem como para a pontuação da EEB, pelos três últimos modelos destacados, é possível afirmar que os modelos permitem uma classificação com acurácia de 100%, pois como o erro sempre é menor que a discretização adotada na escala, o especialista não será influenciado pelos modelos para fornecer uma classificação diferente daquela fornecida com a aplicação da forma tradicional de qualquer uma das duas escalas, EEB ou TUG Test. Um dos estudos mais recentes sobre o assunto é o apresentado por HSU et al (2020), no qual os autores utilizam sinais de sensores inerciais obtidos durante a realização do TUG Test para classificar o risco de quedas de idosos, tendo como padrão ouro a saída obtida pela aplicação da EEB. Na Tabela 6 mostramos a comparação entre 5 dos modelos propostos neste estudo e o apresentado por HSU et al (2020).

Tabela 6. Comparação de resultados de técnicas que utilizam inteligência computacional.

Modelo	Entradas	Saída	Acurácia
ENL (HSU, 2020)	Características de sinais obtidos com sensores inerciais durante aplicação do TUG TEST	Risco pela EEB	85%
Modelo PMC T-B S/EC		Risco pela EEB	100%
Modelo SVR B-B S/EC	Características de sinais obtidos com sensores inerciais durante aplicação de 4 atividades da EEB reduzida	Risco pela EEB	100%
Modelo SVR B-T S/EC		Risco pelo TUG Test	100%
Modelo PMC B-T C/EC		Risco pela EEB	100%
Modelo PMC B-B C/EC		Risco pelo TUG Test	100%

É possível perceber que as abordagens propostas permitem um melhor desempenho na classificação do risco de quedas dos idosos. EM parte o melhor desempenho das abordagens propostas neste trabalho pode estar associado ao modelo proposto que estima as pontuações (um regressor) ao invés de tentar classificar diretamente. Contudo, vale a pena observar que as características extraídas por HSU (2020) dos sinais do TUG Test são todas associadas ao domínio do tempo, enquanto neste trabalho adota-se características também no domínio da frequência. Interessante notar que a ferramenta de seleção de atributos sempre seleciona atributos relacionados ao domínio da frequência (vide Tabela 5) quando os sinais de entrada são obtidos via TUG, explicitando a importância da frequência dos sinais do TUG Test para classificar o risco de quedas em idosos, como já fora reportado na literatura. Por outro lado, cabe destacar que a amostra utilizada nos experimentos apresentados neste trabalho é composta por 32 pacientes, enquanto o banco de dados utilizado por HSU (2020) dispõe dos dados de 120 voluntários.

4. CONCLUSÕES

A queda é um grave problema de saúde pública, principalmente em idosos, e no intuito de contribuir para prevenção e diagnóstico de risco várias ferramentas têm sido propostas na atualidade, inclusive abordagens que utilizam sensores, processamento de sinais e inteligência computacional. As ferramentas de inteligência computacional, geralmente, estão sendo aplicadas na avaliação do risco de quedas em idosos como recurso de classificação de idosos com alto e baixo risco de quedas.

Neste trabalho foram apresentados modelos que utilizam os algoritmos PMC e SVR para estimar as pontuações de idosos na EEB e no TUG Test, com base em dados coletados por sensores inerciais. A ideia de propor um estimador funcional em vez de um classificador baseia-se no fato de que as escalas podem apresentar diferentes notas de corte dependendo das características da população em que ela é aplicada e das características dos idosos. Assim, fica a cargo de um especialista determinar o risco de quedas, considerando as notas informadas pelos modelos propostos, de acordo com as características da população ou considerando outros fatores que o especialista julgar pertinentes. A abordagem proposta apresentou ótimos resultados, com erros de estimação muito baixos e com uma correlação entre as pontuações reais e as estimadas próxima a 1 para os melhores modelos. Considerando os erros apresentados pelos modelos propostos neste trabalho foi possível obter-se no teste 100% de acerto na classificação do risco de quedas, tanto quando o risco é estimado pela EEB quanto quando o risco é estimado pelo TUG Test.

A expectativa de novos estudos com esse escopo é justificável, uma vez que o aumento do número de idosos tende a aumentar a demanda de atendimento especializado e o uso dessas ferramentas pode melhorar a assistência desses voluntários, auxiliando os profissionais responsáveis. Como trabalhos futuros pretendemos investigar a possibilidade de utilizar menos atividades da EEB para realizar a estimação da pontuação da EEB completa e do tempo do TUG Test, mantendo a precisão próxima das obtidas neste estudo. Também pretendemos realizar o acompanhamento dos voluntários que participaram deste estudo por um período de mínimo de dois anos, a fim de verificar quais idosos caíram ou não.

REFERÊNCIAS

- ALMEIDA, Sionara Tamanini de et al. Análise de fatores extrínsecos e intrínsecos que predisõem a quedas em idosos. Rev. Assoc. Med. Bras., São Paulo, v. 58, n. 4, p. 427-433, Agosto. 2012.
- ANDRADE, Sara Rosa de Sousa et al. AVALIAÇÃO DO EQUILÍBRIO E RISCO DE QUEDA EM IDOSOS INSTITUCIONALIZADOS. Referências em Saúde da Faculdade Estácio de Sá de Goiás-RRS-FESGO, v. 2, n. 2, 2019.
- ANSAI, Juliana Hotta et al. Revisão de dois instrumentos clínicos de avaliação para prever risco de quedas em idosos. Revista brasileira de geriatria e gerontologia, v. 17, n. 1, p. 177-189, 2014.

- BELASCO, Angélica Gonçalves Silva; OKUNO, Meiry Fernanda Pinto. Realidade e desafios para o envelhecimento. *Revista Brasileira de Enfermagem*, v. 72, p. 1-2, 2019.
- BLUM, Lisa; KORNER-BITENSKY, Nicol. Usefulness of the Berg Balance Scale in stroke rehabilitation: a systematic review. *Physical therapy*, v. 88, n. 5, p. 559-566, 2008.
- CABY, Benoit et al. Feature extraction and selection for objective gait analysis and fall risk assessment by accelerometry. *Biomedical engineering online*, v. 10, n. 1, p. 1-19, 2011.
- CARVALHO, Maitê Peres de et al. Quedas e fatores associados em idosos institucionalizados no município de Pelotas (RS, Brasil). *Ciênc. saúde coletiva*, Rio de Janeiro, v. 16, n. 6, p. 2945-2952, Junho 2011.
- CRUZ, Danielle Teles da et al. Prevalência de quedas e fatores associados em idosos. *Rev. Saúde Pública*, São Paulo, v. 46, n. 1, p. 138-146, Fevereiro. 2012.
- DA CRUZ, Danielle Teles et al. Associação entre capacidade cognitiva e ocorrência de quedas em idosos. *Cadernos Saúde Coletiva*, v. 23, n. 4, 2015.
- DE BARROS, I. F. O., PEREIRA, M. B., WEILLER, T. H., ANVERSA, E. T. R. Internações hospitalares por quedas em idosos brasileiros e os custos correspondentes no âmbito do Sistema Único de Saúde. *Revista Kairós: Gerontologia*, v. 18, n. 4, p. 63-80, 2015.
- DE SOUSA, Felipe Augusto et al. Uso da Gameterapia para o Tratamento do Déficit de Equilíbrio e Avaliar o Risco de Quedas em Idosos de uma Universidade Aberta em Anápolis. *Anais da Mostra Acadêmica do Curso de Fisioterapia*, v. 7, n. 2, p. 167-171, 2019.
- FERRARESI, J.R; PRATA, M.G; SCHEICHER, M.E.: Assessment of balance and level of functional independence of elderly persons in the community, *Rev. bras. geriatr. gerontol*, São Paulo, v 18, n 3, p 499-506.2015.
- GREENE, Barry R. et al. Quantitative falls risk assessment using the timed up and go test. *IEEE Transactions on Biomedical Engineering*, v. 57, n. 12, p. 2918-2926, 2010.
- GREENE, Barry R. et al. Quantitative falls risk estimation through multi-sensor assessment of standing balance. *Physiological measurement*, v. 33, n. 12, p. 2049, 2012.
- HOWCROFT, Jennifer; KOFMAN, Jonathan; LEMAIRE, Edward D. Feature selection for elderly faller classification based on wearable sensors. *Journal of neuroengineering and rehabilitation*, v. 14, n. 1, p. 1-11, 2017.
- HSU, Yu-Cheng et al. A novel approach for fall risk prediction using the inertial sensor data from the timed-up-and-go test in a community setting. *IEEE Sensors Journal*, v. 20, n. 16, p. 9339-9350, 2020.
- JUNIOR, Cesar Luis Buzin; ADAMI, Andre Gustavo. SDQI Fall Detection System for Elderly. *IEEE Latin America Transactions*, v. 16, n. 4, p. 1084-1090, 2018.
- KARUKA, A.H; SILVA, J.A.M.G; NAVEGA,M.T.: Análise da concordância entre instrumentos de avaliação do equilíbrio corporal em idosos, *Rev. bras. fisioter*, São Carlos v 15, n 6, Nov./Dez. 2011.
- LI, Qiang et al. Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information. In: *BSN*. 2009. p. 138-143.
- MARSCHOLLEK, Michael et al. Sensors vs. experts-a performance comparison of sensor-based fall risk assessment vs. conventional assessment in a sample of geriatric patients. *BMC medical informatics and decision making*, v. 11, n. 1, p. 1-7, 2011.
- OLIVER, David et al. A systematic review and meta-analysis of studies using the STRATIFY tool for prediction of falls in hospital patients: how well does it work?. *Age and ageing*, v. 37, n. 6, p. 621-627, 2008.
- SHUMWAY-COOK, Anne; BRAUER, Sandy; WOOLLACOTT, Marjorie. Predicting the probability for falls in community-dwelling older adults using the Timed Up & Go Test. *Physical therapy*, v. 80, n. 9, p. 896-903, 2000.
- VALDUGA, R; Lopes, B S; Farias, D L; Nascimento, D da C; Vieira, D C L; Valduga, L V A; Prestes, J; Carvalho, G de A. Risco de quedas e sua relação com a funcionalidade e medo de cair em idosos. *R. bras. Ci. e Mov*; 24(1): 153-166.; 2016.