
**PROGRAMA DE PÓS-GRADUAÇÃO EM DESENVOLVIMENTO HUMANO E
TECNOLOGIAS**

**ANÁLISE DO POSICIONAMENTO E DESLOCAMENTO ARTICULAR EM
EXERCÍCIOS RESISTIDOS POR MODELOS OCULTOS DE MARKOV:
DESENVOLVIMENTO E VALIDAÇÃO DO MÉTODO**

ANDRÉ BAIROS PERES

**PROGRAMA DE PÓS-GRADUAÇÃO EM DESENVOLVIMENTO HUMANO E
TECNOLOGIAS**

**ANÁLISE DO POSICIONAMENTO E DESLOCAMENTO ARTICULAR EM
EXERCÍCIOS RESISTIDOS POR MODELOS OCULTOS DE MARKOV:
DESENVOLVIMENTO E VALIDAÇÃO DO MÉTODO**

ANDRÉ BAIROS PERES

Tese apresentada ao Instituto de Biociências do Câmpus de Rio Claro, Universidade Estadual Paulista, como parte dos requisitos para obtenção do título de Doutor em Desenvolvimento Humano e Tecnologias.

P437a Peres, André Bairros
Análise do posicionamento e deslocamento articular em
exercícios resistidos por modelos ocultos de Markov:
desenvolvimento e validação do método / André Bairros Peres.
-- Rio Claro, 2020
101 f. : il., tabs., fotos

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Instituto de Biociências, Rio Claro
Orientador: Dalton Müller Pessoa Filho

1. Modelos matemáticos. 2. Reconhecimento de padrões. 3.
Biomecânica. 4. Exercícios físicos. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do
Instituto de Biociências, Rio Claro. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Análise do posicionamento e deslocamento articular em exercícios resistidos por modelos ocultos de Markov: desenvolvimento e validação do método

AUTOR: ANDRÉ BAIROS PERES

ORIENTADOR: DALTON MULLER PESSÔA FILHO

Aprovado como parte das exigências para obtenção do Título de Doutor em DESENVOLVIMENTO HUMANO E TECNOLOGIAS, área: Tecnologias nas Dinâmicas Corporais pela Comissão Examinadora:



Prof. Dr. DALTON MULLER PESSÔA FILHO

Departamento de Educação Física / UNESP - Faculdade de Ciências de Bauru - SP

Prof. Dr. SERGIO TOSI RODRIGUES

Departamento de Educação Física / UNESP - Faculdade de Ciências de Bauru - SP

Prof. Dr. CLEITON DOMINGOS MACIEL

Coord. de Pesquisa, inovação e Pós-Graduação / Instituto Federal de São Paulo - Itaquaquecetuba / SP

Prof. Dr. CASSIANO MERUSSI NEIVA

Departamento de Educação Física / UNESP - Faculdade de Ciências de Bauru - SP

Prof. Dr. JOSÉ AMÉRICO DE MELLO FILHO

Departamento de Engenharia Rural / Universidade Federal de Santa Maria - RS

Rio Claro, 11 de setembro de 2020

AGRADECIMENTOS

Ao meu orientador, Prof. Dr. Dalton Müller Pessoa Filho, pela condução desta pesquisa, pela disponibilidade, confiança, amizade, por seus ensinamentos e orientações na construção do conhecimento. Agradeço pela atenção, pelas conversas, mensagens e por todo o tempo a mim dedicado.

Aos meus familiares pelo apoio.

Aos integrantes do Laboreh, pela ajuda e companheirismo.

Ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, por possibilitar minha dedicação à qualificação.

Para nos conhecermos, devemos ir além da esfera de nossas percepções sensoriais (TESLA, 1905)

RESUMO

Identificar a estabilidade do posicionamento articular humano permite a análise de perfis comuns durante as ações motoras de transporte de objetos e do próprio corpo. Esta análise apresenta grande relevância em algumas atividades profissionais que exigem a comparação entre seres, objetos ou ações. Dentre as atividades laborais nas quais o reconhecimento de padrões se torna importante está a postura, o desempenho motor e o distúrbio locomotor patológico. O uso de tecnologias permite ao profissional obter informações mais precisas durante a análise dos diferentes perfis motores e permitir um julgamento apropriado quanto à necessidade de melhorias de controle das ações. Os modelos ocultos de Markov - MOM são modelos estatísticos com grande aplicabilidade e eficiência no reconhecimento de padrões. Este trabalho analisou o uso de MOM no reconhecimento de alterações de posições articulares que modificam a execução de referência de exercícios físicos resistidos: rosca direta e agachamento livre. Dez voluntários realizaram três execuções de cada exercício com diferentes cargas: 0%, 25% e 50% do peso corporal para o exercício de rosca e 0%, 50% e 75% para o agachamento. As execuções foram gravadas em câmera de vídeo digital, considerando apenas movimentos no plano sagital. Dados de deslocamentos de articulações foram obtidos mediante captura de coordenadas cartesianas das trajetórias percorridas. Análises de variância identificaram as execuções que sofreram alterações significativas ($p < 0,05$) de valores de deslocamento com as alterações de carga. MOM treinados com dados de execuções sem carga conseguiram distinguir as execuções que sofreram alterações do padrão de movimentos pelo aumento da carga. Profissionais da área também analisaram os movimentos das articulações e os resultados de suas avaliações atingiram até 90% de concordância com o modelo proposto. Os resultados obtidos mostraram que MOM apresentam viabilidade na identificação de alterações de padrão de movimentos mono e multiarticulares, com sobrecarga, pela análise de posicionamento articular. Mostraram também possibilidade de serem avaliados os movimentos registrados em vídeos obtidos sem qualquer referência métrica de dados. Com a participação de avaliadores humanos também se mostrou o alinhamento do método com a interpretação profissional de execuções adequadas.

Palavras-chave: Reconhecimento de padrões, Movimento humano, Rosca direta, Agachamento livre.

ABSTRACT

Identifying the stability of the human joint position allows the analysis of common profiles during the motor actions of transporting objects and the body itself. This analysis is highly relevant in some professional activities that require comparison between beings, objects, or actions. Among the work activities in which pattern recognition becomes important are posture, motor performance, and pathological disturbance of locomotor system. The use of technologies allows the professional to obtain information that is more accurate during the analysis of the different locomotor profiles and allows an appropriate judgment as to the need for control improvements. The hidden Markov models - HMM are statistical models with great applicability and efficiency in pattern recognition. This work analyzed the use of HMM in recognizing changes in joint positions that modify the reference execution of resisted physical exercises: barbell curls and free squats. Ten volunteers performed three executions of each exercise with different loads: 0%, 25%, and 50% of the bodyweight for the biceps exercise and 0%, 50%, and 75% for the squat exercise. The executions were recorded on a digital video camera, considering only movements in the sagittal plane. Joint displacement data were obtained by capturing Cartesian coordinates of the trajectories covered. Analysis of variance identified the executions that underwent significant changes ($p = 0.05$) of displacement values with changes in load. HMM trained with data of executions without load were able to distinguish the executions that suffered changes in the movement pattern due to the increase in the load. Professionals in the area also analyzed the movements of the joints and the results of their assessments reached up to 90% agreement with the proposed model. The results obtained showed that MOM is feasible in identifying changes in the pattern of mono and multiarticular movements, with overload, by analyzing joint positioning. They also showed the possibility of evaluating movements recorded in videos obtained without any metric data reference. With the participation of human evaluators, the alignment of the method with the professional interpretation of appropriate executions was also shown.

Keywords: Pattern recognition, Human movement, Biceps curl, Free squat.

LISTA DE ABREVIATURAS

Lista de abreviaturas empregadas no texto, descritas em ordem alfabética

Sigla	Descrição
CSV	Comma Separated Values
MOM	Modelos Ocultos de Markov
LABOREH	Laboratório de Optimização do Rendimento Esportivo Humano
MP4	Motion Picture Experts Group-4 Part 14
MPEG-4	Motion Picture Experts Group-4
NSCA	National Strength and Conditioning Association
UHD	Ultra High Definition
XML	Extensible Markup Language

LISTA DE FIGURAS

Figura 1 - Representação de uma cadeia de Markov com quatro estados.	16
Figura 2 – Exemplo das urnas com bolas coloridas.	17
Figura 3 - Representação gráfica de um MOM discreto com 3 estados.....	19
Figura 4 - Diagrama de fluxo de estudo do PRISMA.....	31
Figura 5 - Posicionamento e execução do exercício de rosca direta com barra. A - Posição inicial com vista frontal. B - Posição inicial com vista lateral. C - Movimento ascendente do exercício com vista frontal. D - Movimento ascendente com vista lateral.	41
Figura 6 - Posicionamento para execução do exercício de agachamento com carga em barra.....	42
Figura 7 - Posições do movimento descendente na execução do exercício de agachamento livre com barra.....	43
Figura 8 - Posição final do movimento ascendente na execução do exercício de agachamento livre com barra.....	43
Figura 9 - Representação de um plano sagital.....	46
Figura 10 - Espaço destinado a realização dos exercícios.	52
Figura 11 - Fixação de marcadores semiesféricos de cor verde nos participantes. ...	52
Figura 12 - Localização dos marcadores no corpo do participante para o exercício de agachamento livre com barra.....	53
Figura 13 - Localização dos marcadores no corpo do participante para o exercício de rosca direta com barra.	54
Figura 14 - Esquema para captura dos vídeos.....	55
Figura 15 - Exemplo de aplicação de filtros nos vídeos. Em A está a imagem do vídeo original. Em B exibe a aplicação do efeito <i>Chroma Key</i> que localiza e altera a cor dos marcadores. E em C está a aplicação do canal Alfa que subtrai praticamente tudo que não foi selecionado pelo <i>Chroma Key</i>	56
Figura 16 - Trajetória descrita por cada marcador durante a realização de um exercício de rosca direta com barra. Rastreamento obtido com o software Kinovea.	57
Figura 17 - Tela de escolha da origem do sistema de coordenadas e calibração do Kinovea.	57
Figura 18 - Representação gráfica de um MOM de topologia linear com cinco estados.....	60

Figura 19 - Gráfico da trajetória curva descrita por um marcador fixado à barra durante a realização de uma execução do exercício de rosca direta com barra.....	60
Figura 20 - Conjunto de pontos formadores da trajetória percorrida por um marcador fixado na barra durante uma execução ascendente do exercício de rosca direta com barra. A figura exhibe a formação de três clusters (azul, verde e vermelho) com três centroides indicados pelos símbolos ×.....	62
Figura 21 - Visualização da existência de estados dos MOM em um exercício de rosca direta com barra com dados de posições bidimensionais divididos em três clusters.....	62
Figura 22 – Fluxograma referente a metodologia do estudo.....	65
Figura 23 - Gráficos de Bland-Altman (para exercício de rosca direta) indicando a diferença média (eixo y) e os limites de concordância de 95% ($DP * 1,95$, linhas pontilhadas mais largas) entre as duas formas de análise pelos MOM: com mensurações no ambiente (CA) e somente com coordenadas de imagem (CI).	74
Figura 24 - Gráficos de Bland-Altman (para exercício de agachamento) indicando a diferença média (eixo y) e os limites de concordância de 95% ($DP * 1,95$, linhas pontilhadas mais largas) entre as duas formas de análise pelos MOM: com mensurações no ambiente (CA) e somente com coordenadas de imagem (CI).	75
Figura 25 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de rosca direta. Comparação 0% - 50% de carga.	76
Figura 26 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de agachamento. Comparação 0% - 50% de carga.	77
Figura 27 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de rosca direta. Comparação 0% - 75% de carga.	77

LISTA DE TABELAS

Tabela 1 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), sem carga (0%, condição referência) em cada uma das três execuções para cada participante. Valores mensurados em centímetros (cm). 66	66
Tabela 2 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), com carga de 25% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros (cm). 67	67
Tabela 3 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), com carga de 50% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.67	67
Tabela 4 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), sem carga (0%) em cada uma das três execuções para cada participante. Valores mensurados em centímetros.70	70
Tabela 5 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), com carga de 50% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.....70	70
Tabela 6 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), com carga de 75% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.....71	71
Tabela 7 – Valores da estatística <i>kappa</i> (<i>k</i>). Valores referentes ao exercício de rosca.78	78
Tabela 8 – Valores da estatística <i>kappa</i> (<i>k</i>). Valores referentes ao exercício de agachamento na comparação 0% - 50% de carga.....79	79
Tabela 9 – Valores da estatística <i>kappa</i> (<i>k</i>). Valores referentes ao exercício de agachamento na comparação 0% - 75% de carga. O “NC” significa que não houve cálculo pois os resultados do Avaliador 02 foram constantes.79	79

LISTA DE QUADROS

Quadro 1 – Dados dos artigos utilizados na revisão.	32
Quadro 2 – Postura e técnica de execução de rosca direta com barra.....	40
Quadro 3 – Postura e técnica de execução de agachamento livre com barra.	42
Quadro 4 - Valores para interpretação dos resultados da estatística Kappa.	59
Quadro 5 – Valores mínimos para o número de estados (N) dos MOM necessários para orientar o reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas (p) por participante.....	69
Quadro 6 – Valores mínimos para o número de estados (N) dos MOM necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas (p) por participante (exercício de agachamento).	72
Quadro 7 – Valores mínimos para o número de estados (N) dos MOM, necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas por participante. Valores obtidos somente com dados de imagem (rosca direta). Os três pontos (...) indicam que não foi encontrada diferença significativa pela ANOVA.....	73
Quadro 8 – Valores mínimos para o número de estados (N) dos MOM necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas por participante. Valores obtidos somente com dados de imagem (agachamento). Os três pontos (...) indicam que não foi encontrada diferença significativa pela ANOVA.	75

SUMÁRIO

1 INTRODUÇÃO	11
2 REVISÃO DE LITERATURA	14
2.1 Modelos Ocultos de Markov	14
2.1.1 Desenvolvimento histórico	14
2.1.2 Cadeias de Markov	15
2.1.3 Os Modelos Ocultos de Markov	16
2.1.4 Aplicações dos MOM	25
2.2 Uso de modelos Markovianos com coordenadas cartesianas para modelagem de movimentos humanos: uma revisão sistemática	28
2.3 Movimentos na execução de exercícios físicos	37
2.3.1 Exercício monoarticular: rosca direta com barra	39
2.3.2 Exercício multiarticular: agachamento livre com barra	41
2.3.3 Execução de habilidades motoras.....	44
3 JUSTIFICATIVA.....	48
4 OBJETIVOS.....	49
4.1 Objetivo geral	49
4.2 Objetivo específico	49
5 HIPÓTESES.....	50
6 MÉTODOS	51
7 RESULTADOS.....	66
7.1 Mensurações, ANOVAS e MOM.....	66
7.2 MOM sem referência de coordenadas no espaço.....	72
7.3 Avaliadores humanos.....	76
8 DISCUSSÃO	80
9 CONSIDERAÇÕES FINAIS	86
10 REFERÊNCIAS.....	87

1 INTRODUÇÃO

O reconhecimento de padrões é uma capacidade do ser humano. Mesmo sem perceber, o ser humano é capaz de reconhecer padrões nas mais diversas situações do cotidiano. O simples ato de andar por uma avenida movimentada aciona a execução de variadas formas de reconhecimento: padrões de vestuário e tipos de vozes de transeuntes, modelos veiculares, sinais de trânsito, tonalidades de cores, fachadas prediais, reconhecimento geofotográfico instantâneo, entre outras. Acabamos instantaneamente associando as imagens ou sons a outros que já tenhamos tido contato. Neste ato de associar o que vemos, ouvimos ou sentimos a um padrão semelhante, registrado em nossa mente, está implícito que há alguma forma de comparação (CASTRO; PRADO, 2002).

Esta capacidade de reconhecer padrões pode ir mais além do apenas reconhecer um determinado modelo, mas também de avaliar o quanto o padrão observado corresponde a outro tomado como referencial. Na área profissional da Educação Física, essa habilidade apresenta grande relevância para avaliação da qualidade do trabalho a ser desenvolvido. Por exemplo, um educador físico deve observar se o movimento realizado por seu aluno está de acordo com o definido como correto para aquele exercício/tratamento (AMADIO; SERRÃO, 2007; KNUDSON; MORRISON, 2001; MARQUES, 1995). Esta forma de avaliação do movimento pode ser obtida a partir da observação de características comuns deste movimento e muitas destas avaliações seguem sendo realizadas de forma subjetiva (MENDES et al., 2012).

Com o avanço da tecnologia há algumas décadas, as formas de reconhecimento de padrões por meio de técnicas estatísticas, matemáticas e até mesmo de Inteligência Artificial ganharam espaço e importante relevância tendo em vista a grande capacidade de processamento e armazenamento de informações (CHERIET et al., 2007), além de atenuar em parte a subjetividade das análises. Os recursos computacionais atuais já podem, em alguns casos, assumir tarefas que geralmente são realizadas por seres humanos, podendo até mesmo realizá-las de forma mais confiável e rápida. Tenta-se com a tecnologia superar algumas capacidades humanas em certas áreas, mas isso ainda é uma tarefa difícil que exige muita pesquisa e elaboração de algoritmos e métodos computacionais cada vez mais complexos.

Dentre os métodos estatísticos de maior aplicação em reconhecimento de padrões estão os Modelos Ocultos de Markov – MOM (FINK, 2008; RABINER; JUANG, 1986). Os MOM utilizam técnicas probabilísticas para modelar dados sequenciais representados por uma sequência de dados observáveis. Nos MOM há processos ocultos que consistem de um conjunto de estados conectados por probabilidades de transições, enquanto que os processos observáveis consistem de um conjunto de saídas ou observações, cada qual pode ser emitida por cada estado (OLIVEIRA; MORITA, 2005; RABINER; JUANG, 1986). O reconhecimento de padrões nos MOM consiste na comparação entre modelo de referência e o estabelecimento de regra de decisão. Essa regra é efetuada, geralmente, por meio da medida da verossimilhança entre o objeto a ser analisado com o modelo de referência, sendo este obtido numa fase anterior, chamada de aprendizado (JUSTINO, 2001).

O desenvolvimento de métodos de reconhecimento de padrões com base nos chamados modelos Markovianos se deu junto a pesquisas no campo do reconhecimento automático de fala (RABINER; JUANG, 1993). Atualmente os MOM também são aplicados em muitos outros campos onde a tarefa é a modelagem e análise de dados organizados cronologicamente (ou sequencialmente), como por exemplo em reconhecimento de sequências genéticas humanas (FINK, 2008; OSMAN et al., 2017). Do ponto de vista do reconhecimento estatístico de padrões, a informação genética analisada por MOM, consiste essencialmente em sequências de símbolos organizados de forma linear (FINK, 2008).

As novas técnicas de processamento de imagens associadas à evolução computacional contribuem de forma significativa para técnicas de reconhecimento de padrões em espaços bi e tridimensionais. Os MOM são bem empregados em análise de padrões contidos em imagens. Emprega-se MOM no reconhecimento de placas veiculares (DARAMOLA et al., 2011; LEE et al., 2003; ZHANG; LUO; ZHU, 2010), de assinaturas (JUSTINO; BORTOLOZZI; SABOURIN, 2001; SAINI et al., 2018; VAN; GARCIA-SALICETTI; DORIZZI, 2007; YANG; WIDJAJA; PRASAD, 1995), de palavras manuscritas (BOGACZ; KLINGMANN; MARA, 2017; EL-YACOUBI et al., 1999a; KATANFOROUSH; REZVANI, 2015; KOERICH; SABOURIN; SUEN, 2003; PLOETZ; FINK, 2011), de rostos e expressões faciais humanas (BORUAH; SARMA; TALUKDAR, 2015; SAMARIA; HARTER, 1994; ZHUANG et al., 2008) e de movimentos realizados por seres humanos (AOKI; VENTURE; KULIC, 2013; KARG et al., 2013; KWON; PARK, 2006; MANNINI; SABATINI, 2011).

Reconhecer diferentes tipos de movimentos humanos por meio de um sistema computacional se constitui em uma tarefa complexa, mas com grande aplicabilidade e relevância. Com os recursos computacionais atualmente disponíveis no mercado associados à modelagem Markoviana há a possibilidade de se realizar a supervisão de forma automatizada dos movimentos executados por uma pessoa, por exemplo, durante a realização de atividades físicas. Nesse contexto, o presente trabalho teve como propósito examinar a viabilidade do uso de MOM para análise do posicionamento e deslocamento articular em exercícios resistidos no que tange à sua capacidade em reconhecer mudanças de padrão do movimento. Serão analisados dados provenientes de captura, em câmera digital com obtenção de coordenadas bidimensionais, de diferentes articulações do corpo humano durante a realização de dois tipos de exercícios físicos resistidos: rosca direta com barra e agachamento livre com barra. Espera-se também com o uso dos MOM obter um método de supervisão de exercícios físicos que proporcione ao avaliador, subsídios mais objetivos para implementação e avaliação da qualidade da execução do exercício.

2 REVISÃO DE LITERATURA

Essa revisão está organizada de seguinte forma: primeiramente se faz uma introdução aos modelos ocultos de Markov. Logo após, com base em uma revisão sistemática, se apresentam estudos que utilizam coordenadas bidimensionais associadas aos MOM em movimentos produzidos por humanos. Ao final se faz um levantamento sobre o estudo de movimentos para realização de exercícios físicos.

2.1 Modelos Ocultos de Markov

Neste tópico é abordado o desenvolvimento da teoria dos MOM desde a descoberta das cadeias de Markov. Também se descreve a estrutura matemática do modelo e suas formas de aplicação.

2.1.1 Desenvolvimento histórico

O matemático russo Andrey Andreyevich Markov (14 de junho de 1856 - 20 de julho de 1922) tornou-se conhecido por seus trabalhos sobre probabilidade com variáveis aleatórias. Sua área de pesquisa mais tarde ficou conhecida como processo de Markov e cadeias de Markov. As cadeias de Markov tiveram origem em um trabalho no qual em um texto ele estudava a probabilidade de uma consoante ocorrer em uma determinada posição de uma palavra qualquer. Como hipótese, ele supôs que a probabilidade deveria depender apenas se a letra precedente à consoante fosse uma vogal ou outra consoante (DELONE, 2005).

A aplicação dos modelos de Markov tem uma vasta história em diferentes campos de pesquisa. Importantes avanços ao final da década de 1960 começaram a permitir a análise automática e eficiente de dados de sinal dependentes do tempo para cenários da vida real. Baum e Petrie (1966) publicaram uma série de artigos lançando as bases para resolução de questões associadas aos Modelos Ocultos de Markov. As primeiras aplicações dessa modelagem estavam voltadas para o reconhecimento de fala, sendo os trabalhos produzidos na *International Business Machines Corporation* - IBM e *Carnegie Mellon University* - CMU, no começo dos anos 1970, os primeiros no uso de MOM. Na segunda metade da década de 80, os MOM foram aplicados em sequenciamento de cadeias de DNA, alcançando posteriormente grande importância

em todo o campo da bioinformática (ESPINDOLA, 2009). Nas últimas décadas, esse conceito também foi transferido para o domínio do reconhecimento de caligrafia (PLOETZ; FINK, 2011).

2.1.2 Cadeias de Markov


Cadeias de Markov são processos estocásticos¹ em espaços de estados discretos, nos quais a probabilidade de um estado ocorrer no tempo futuro depende unicamente do estado presente. Matematicamente, se define como um conjunto de S estados denotados por $S_i = \{S_1, S_2, \dots, S_N\}$ para $i = 1 \dots N$. No decorrer do tempo discreto indicado pelo índice t , temos uma sequência de estados indicados por S_t onde a probabilidade de ocorrer um estado de S_j no instante S_{t+1} depende apenas do estado de S_t (HILLIER; LIEBERMAN, 2006; RABINER; JUANG, 1986). A probabilidade de transição, de um estado i para um estado j pode ser denotada por a_{ij} da seguinte forma:

$$a_{ij} = P[S_{t+1} = j \mid S_t = i], \quad 1 \leq i, j \leq N. \quad (1)$$

Desta forma a probabilidade condicionada do modelo passar para o estado S_j no tempo $t + 1$ depende apenas do estado S_i no tempo t . Em regra geral, não existe exigência para que as probabilidades de transição entre dois estados sejam iguais ou para que não ocorra transição entres estados (DUDA; HART; STORK, 2001). A Figura 01 mostra um exemplo de representação de uma cadeia de Markov.

¹ Considera-se como sendo um processo estocástico um fenômeno que varia em algum grau, de forma imprevisível, com o passar do tempo. Também podem ser compreendidos como uma coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos que são observados ao longo do tempo (CLARKE; DISNEY, 1979).

Figura 1 - Representação de uma cadeia de Markov com quatro estados.




Os círculos representam os estados S_i e as setas representam as probabilidades de transição a_{ij} . Em qualquer passo t o sistema encontra-se em um estado particular S_t .

Fonte: Adaptado (SILVA, 2015).

2.1.3 Os Modelos Ocultos de Markov

Os modelos ocultos de *Markov*, são formados por uma cadeia de estados (cadeias de *Markov*) e possuem dois processos estocásticos associados, um envolvendo as transições entre os estados e outro envolvendo as observações de saída de cada estado. As observações de saída são manifestações do fenômeno modelado, e são descritas por funções probabilísticas (DIAS, 2000; RABINER; JUANG, 1986). Para entender como os MOM podem gerar uma sequência de observações, vamos considerar o seguinte exemplo: existem urnas contendo um grande número de bolas coloridas. Uma pessoa tem que pegar bolas de urnas, selecionadas de maneira aleatória, sem que qualquer pessoa veja de qual urna cada bola está sendo retirada (Figura 2).

Figura 2 – Exemplo das urnas com bolas coloridas.



Fonte: Adaptado (RABINER; JUANG, 1986).

As urnas representam os estados dos MOM e sua escolha está associada a uma probabilidade (distribuição inicial dos estados) sem que alguém esteja observando (processo oculto). A primeira bola retirada de uma urna, de forma aleatória, terá uma cor associada a uma probabilidade (probabilidade de sair aquela cor em um conjunto de cores distintas). Depois que a cor da bola é observada (observáveis do modelo/símbolo emitido), a bola é recolocada na mesma urna. Logo após, uma nova urna é selecionada aleatoriamente e outra bola é retirada. Esse processo aleatório é repetido tantas vezes quanto determinado e gera uma sequência das cores de bolas observadas, enquanto que a sequência de estados (urnas) permanece oculta.

Desta forma os MOM descrevem um processo estocástico de dois estágios com estados ocultos e saídas observáveis. O primeiro estágio representa um processo estocástico discreto, que produz uma série de variáveis aleatórias que assumem valores de um conjunto discreto de estados. Este processo é estacionário, o que significa que suas propriedades estatísticas não mudam com o tempo. As duas últimas propriedades juntas restringem a dependência das distribuições de probabilidade dos estados gerados pelas variáveis aleatórias para dependerem apenas do estado predecessor imediato. O processo de Markov conforme descrito é então dito de Primeira Ordem (PLOETZ; FINK, 2011).

$$P(S_t|S_1, S_2, \dots, S_{t-1}) = P(S_t|S_{t-1}) \quad (2)$$

Basicamente, este primeiro estágio representa um processo automatizado com um número finito de estados, que se comporta probabilisticamente. No segundo estágio, então a cada tempo t uma saída O_t é gerada, dependendo somente do estado atual S_t (PLOETZ; FINK, 2011):

$$P(O_t|O_1 \dots O_{t-1}, S_1 \dots S_t) = P(O_t|S_t) \quad (3)$$

Como somente essas saídas O_t , e não os estados internos associados, podem ser observadas, o modelo geral é chamado de Modelo Oculto de Markov. Em geral MOM discretos possuem os seguintes elementos (EL-YACOUBI et al., 1999b; RABINER; JUANG, 1986):

- N representa o número de estados do modelo;
- $S = \{S_1, S_2, \dots, S_N\}$ corresponde ao conjunto dos estados individuais do modelo;
- M representa o número de observações distintas por estado;
- $O = \{o_k\}, k = 1, \dots, M$ corresponde ao conjunto de observações individuais;
- $A = \{a_{ij}\}$ corresponde a distribuição de probabilidades de transição dos estados em que:

$$A = \{a_{ij} = P(S_j \text{ a } t + 1 | S_i \text{ a } t)\}, \quad t = 1, \dots, T. \quad (4)$$


- $B = \{b_{ik}\}$ corresponde a distribuição de probabilidade da observação em cada estado;

$$B = \{b_{ik} = b_i(O_k) = P(O_k | S_i)\} \quad (5)$$

- $\pi = \{p_i = P(S_i \text{ a } t = 1)\}$ corresponde a distribuição inicial dos estados;
- λ representa o modelo dado por $\lambda = \{A, B, \pi\}$.

Na Figura 3, estão exibidos os elementos a_{ij} da matriz A que representa as probabilidades de transição do estado S_i para o estado S_j e b_{ik} e os elementos da matriz B , que representa as distribuições de probabilidade de observação em S_j (KWON; PARK, 2008).

Figura 3 - Representação gráfica de um MOM discreto com 3 estados.



Fonte: Adaptado (DYMARSKI, 2011).

A aplicação dos MOM requer a resolução de três problemas fundamentais (ESPINDOLA, 2009):

1º - Probabilidade de uma sequência de observáveis.

Sejam o modelo $\lambda = (A, B, \pi)$ e a sequência de observáveis $O = O_1, O_2, \dots, O_T$.

Como calcular de forma eficiente a probabilidade de essa sequência ser gerada pelo modelo $P(O|\lambda)$?

Este problema é resolvido pelos algoritmos *Forward* e *Backward*.

2º - Melhor sequência de estados.

Sejam o modelo $\lambda = (A, B, \pi)$ e a sequência de observáveis $O = O_1, O_2, \dots, O_T$.

Dentre as diversas sequências de estados que poderiam ter gerado essa sequência de observáveis qual é a mais provável?

Este problema é resolvido com o algoritmo de Viterbi.

3º - Maximização da probabilidade de uma sequência de observáveis.

Como ajustamos os parâmetros $\lambda = (A, B, \pi)$ do modelo para maximizar $P(O|\lambda)$?

Este problema é resolvido com o algoritmo de Baum-Welch.

Os algoritmos *Forward* e *Backward*

Seja $\alpha_t(i)$ a probabilidade da sequência de observações $O = O_1, O_2, \dots, O_T$ ser produzida por todas as sequências de estados possíveis que terminam no i -ésimo estado:

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t | S_t = S_i) \quad (6)$$

Então a probabilidade incondicional² da sequência de observação parcial é a soma de $\alpha_t(i)$ sobre todos os estados N .

O algoritmo *Forward*³ é um algoritmo recursivo para calcular $\alpha_t(i)$ para a sequência de observação de comprimento crescente t .

Primeiro, as probabilidades para a sequência de símbolo único são calculadas como um produto da probabilidade do i -ésimo estado inicial e da probabilidade de emissão do símbolo dado O_1 no i -ésimo estado. Então a fórmula recursiva⁴ é aplicada. Suponha que calculamos $\alpha_t(i)$ para algum t . Para calcular $\alpha_{t+1}(j)$, multiplicamos cada $\alpha_t(i)$ pela probabilidade de transição correspondente do i -ésimo estado ao j -ésimo estado, somamos os produtos em todos os estados e depois multiplicamos o resultado pela probabilidade de emissão do símbolo O_{t+1} . Iterando o processo, podemos eventualmente calcular $\alpha_t(i)$ e, em seguida, somando-os sobre todos os estados, podemos obter a probabilidade necessária (GONZÁLEZ, 2012).

O algoritmo é executado da seguinte forma (RABINER, 1989):

a) Inicialização

$$\alpha_0(i) = p_i b_i(O_1), \quad 1 \leq i \leq N \quad (7)$$

b) Indução

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1}), \quad 1 \leq j \leq N, \quad 1 \leq t \leq T - 1 \quad (8)$$

² A probabilidade de um evento ocorrer, não dependendo de nenhum resultado anterior ou relacionado (MEYER, 1987).

³ O uso do algoritmo *Forward* parte da suposição de que não há variável no modelo, apenas o intercepto. A ideia do método é adicionar uma variável de cada vez (a cada passo). A primeira variável selecionada é a que apresenta maior correlação com o modelo.

⁴ A recursão pode ser considerada como um processo de repetição de uma rotina.

c) Probabilidade final (finalização)

$$P(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (9)$$

De forma semelhante, pode-se introduzir uma variável retroativa simétrica $\beta_t(i)$ como a probabilidade condicional da sequência de observação parcial O_{t+1} ser produzida por todas as sequências de estado que começam no i -ésimo estado:

$$\beta_t(i) = P(O_{t+1}, O_{t+2}, \dots, O_T | S_t = S_i) \quad (10)$$

O algoritmo *Backward*⁵ calcula as variáveis regressivas recursivamente retrocedendo ao longo da sequência de observação. O algoritmo *Forward* é tipicamente usado para calcular a probabilidade de uma sequência de observação ser emitida por um MOM. Ambos os procedimentos são muito usados para encontrar a sequência de estado ideal e estimar os parâmetros dos MOM (GONZÁLEZ, 2012).

O algoritmo *Backward* é executado da seguinte forma (RABINER, 1989):

a) Inicialização

$$\beta_T(i) = 1, 1 \leq i \leq N \quad (11)$$

b) Indução

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j), t = T-1, T-2, \dots, 1; 1 \leq i \leq N \quad (12)$$

c) Probabilidade final (finalização), (GONZÁLEZ, 2012; SOARES; COSTA; MATOS, 2015).

$$P(O|\lambda) = \sum_{i=1}^N p_i b_i(O_1) \beta_1(i) \quad (13)$$

⁵ Enquanto o método *Forward* começa sem nenhuma variável no modelo e adiciona variáveis a cada passo, o método *Backward* faz o caminho oposto. Incorpora inicialmente todas as variáveis e depois, por etapas, cada uma pode ser ou não eliminada.

Processo de decodificação

Existem vários critérios para encontrar a sequência mais provável de estados ocultos. Uma delas é escolher estados que são individualmente mais prováveis no momento em que um símbolo é emitido. Essa abordagem é chamada de decodificação (GONZÁLEZ, 2012).

Seja $\lambda_t(i)$ a probabilidade de o modelo emitir o símbolo O_t estando no i -ésimo estado da sequência de observação dada:

$$\lambda_t(i) = P(S_t = S_i | O) \quad (14)$$

Assim:

$$\lambda_t(i) = \alpha_t(i)\beta_t(i)/P(O), 1 \leq i \leq N, 1 \leq t \leq T \quad (15)$$

Então, pode-se selecionar o estado S_t que maximiza $\lambda_t(i)$:

$$S_t = \operatorname{argmax}\{\lambda_t(i)\} \quad (16)$$

Algoritmos de Viterbi e Baum-Welch

O algoritmo de Viterbi⁶ é um algoritmo eficiente para encontrar uma solução ótima (maior probabilidade) sem que se tenha conhecimento da sequência de estados (ocultos). Ele é usado para encontrar o caminho de estados ideais que tem a maior probabilidade associada à sequência de observação dada. Com o caminho do estados ideais, podemos aprender sobre as relações entre estados (LIU; CAI; BUSE, 2003).

O critério de otimização do algoritmo para decodificar a sequência ótima de estados é dado da seguinte maneira (RABINER, 1989):

$$\delta_t(i) = \max_{S_1, S_2, \dots, S_{t-1}, S_t} P(S_1, S_2, \dots, S_{t-1}, S_t, O_1, O_2, \dots, O_t | \lambda) \quad (17)$$

⁶ Algoritmo utilizado para determinar qual o caminho (sequência de estados) mais provável na geração de uma sequência de observações. Considera tanto as probabilidades intervalares de emissão de símbolos em um determinado estado quanto as probabilidades intervalares de transição de estados (SANTOS et al., 2006).

em que $\delta_t(i)$ armazena a maior probabilidade do caminho (sequência única de estados) que leva ao estado i no instante t , gerando uma sequência de observações $O_1, O_2, \dots, O_t$, por indução (SOARES; COSTA; MATOS, 2015), tem-se que:

$$\delta_{t+1}(j) = \max [\delta_t(i)a_{ij}] \cdot b_j(o_{t+1}) \quad (18)$$

Para que se possa recuperar a sequência ótima de estados usa-se um vetor auxiliar $\phi(k)$ que guarda cada posição t o índice j do estado $S_{t-1} = j$ que maximiza a sequência até o estado $S_t = k$. A descrição formal do algoritmo de Viterbi (LIU; CAI; BUSE, 2003; RABINER, 1989) pode ser resumida da seguinte forma:

a) Inicialização

$$\delta_1(i) = \pi_i b_i(O_1), \quad \phi_1(i) = 0, \quad 1 \leq i \leq N \quad (19)$$

b) Recursão

$$\delta_t(j) = \max_i [\delta_{t-1}(i)a_{ij}] b_j(o_t), \quad 1 \leq i \leq N, 2 \leq t \leq T \quad (20)$$

$$\phi_t(i) = \operatorname{argmax}_j [\delta_{t-1}(i)a_{ij}], \quad 1 \leq i \leq N, 2 \leq t \leq T \quad (21)$$

c) Finalização

$$P^* = \max_i [\delta_T(i)], \quad 1 \leq i \leq N \quad (22)$$

$$S_T^* = \operatorname{argmax}_i [\delta_T(i)], \quad 1 \leq i \leq N \quad (23)$$

d) Busca pela sequência de estados ótima (retornar o caminho oculto mais provável)

$$S_t^* = \phi_{t+1}(S_{t+1}^*), \quad t = T - 1, T - 2, \dots, 1 \quad (24)$$

Para maximizar a probabilidade das sequências de observações utiliza-se o algoritmo de Baum-Welch⁷. Neste, como em outros trabalhos, este processo iterativo

⁷ Algoritmo que tem como objetivo gerar novos modelos a partir de um modelo inicial de forma iterativa. Este processo iterativo deve obedecer a um critério de parada (SANTOS et al., 2006).

foi utilizado para treinamento⁸ dos modelos. Na descrição deste modelo (RABINER, 1989b) se define $\xi_t(i, j)$, como a probabilidade de estar no estado S_i no tempo t , e no estado S_j no tempo $t+1$, dado o modelo e a sequência de observações. Pode-se escrever isso da seguinte forma (SANTOS, 2009):

$$\xi_t(i, j) = P(S_t = S_i, S_{t+1} = S_j | O, \lambda) \quad (25)$$

Utilizando as definições das variáveis de *forward* e *backward*, tem-se $\xi_t(i, j)$ da seguinte forma:

$$\xi_t(i, j) = \frac{a_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N a_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)} \quad (26)$$

Em seguida define-se $\gamma_t(i)$ como a probabilidade de estar no estado S_i no tempo t , dada a sequência de observações e o modelo pode-se relacionar $\gamma_t(i)$ com $\xi_t(i, j)$ pelo somatório de j , em que (RABINER, 1989):

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j) \quad (27)$$

Com estas definições, pode-se denotar o número esperado de transições do estado S_i para o estado S_j como:

$$\sum_{t=1}^{T-1} \gamma_t(i) = \text{número esperado de transições de } S_i \quad (28)$$

$$\sum_{t=1}^{T-1} \xi_t(i, j) = \text{número esperado de transições de } S_i \text{ para } S_j \quad (29)$$

⁸ Treinamento, para este assunto, significa otimizar parâmetros dos MOM de modo a maximizar a probabilidade de uma sequência de observações (usadas para treinamento) fazer parte do modelo.

Com as equações anteriores, pode-se fornecer um método de reestimativa de parâmetros de um MOM. O procedimento de reestimativa garante que o modelo fornecido pode ser aprimorado iterativamente. O processo de reestimativa repete-se até que não ocorram melhorias significativas no modelo. O conjunto de equações de reestimativas para π , A , e B é mostrado a seguir.

A probabilidade de estar no estado S_i no tempo ($t = 1$)

$$\bar{\pi} = \gamma_1(i) \quad (30)$$

O número de transições esperadas do estado S_i para o estado S_j dividido pelo número de transições esperadas do estado S_i ,

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (31)$$

E o esperado número do estado j e o símbolo de observação O_k dividido pelo número no estado j é dado da seguinte forma (LIU; CAI; BUSE, 2003; RABINER, 1989; SANTOS, 2009):

$$\bar{b}_j(k) = \frac{\sum_{t=1}^T \gamma_t(i) \text{ s.t. } O_t = O_k}{\sum_{t=1}^T \gamma_t(j)} \quad (32)$$

2.1.4 Aplicações dos MOM

São várias as possibilidades de aplicação dos MOM. Por eles se adaptarem muito bem na análise de dados sequenciais chegam a ser considerados o estado-da-arte na modelagem destes tipos de dados (PLOETZ; FINK, 2011). Como já mencionado na introdução, os MOM tiveram grande destaque no reconhecimento da voz, gerando muitas pesquisas que são referência na aplicação dos MOM. Dentre estes trabalhos estão os produzidos por Lawrence Rabiner e Biing-Hwang Juang (JUANG; RABINER, 1991; RABINER; JUANG, 1993; RABINER, 1989). Rabiner produziu em 1989 um tutorial de uso dos MOM para o reconhecimento de voz que é

um referencial para aplicação dos MOM e possibilitou com seu material o desenvolvimento de muitas outras pesquisas relacionadas.

Os MOM também obtiveram sucesso no reconhecimento de caracteres alfanuméricos, redigidos manualmente ou não. Thomas Plötz e Gernot A. Fink desenvolveram trabalhos relevantes no reconhecimento de caracteres (FINK, 2008; PLOETZ; FINK, 2011). Outros estudos relevantes na mesma área foram desenvolvidos por Abdenain El Yacoubi e seus associados (EL-YACOUBI et al., 1999a, 1999b, 2000). Além destes, muitos outros pesquisadores dedicam seu tempo a pesquisas com reconhecimento de caracteres (BUNKE; ROTH; SCHUKAT-TALAMAZZINI, 1995; FREITAS et al., 2000b; KOERICH, 2004; SAMANTA et al., 2018; SIEBRA LOPES et al., 2016). O reconhecimento de caracteres com uso de MOM ainda é tema de muitas pesquisas atuais.

Mas os MOM também são empregados para o reconhecimento de movimentos realizados por objetos ou seres humanos. Neste estudo o maior interesse é em pesquisas que utilizaram os MOM relacionados ao reconhecimento de gestos ou de qualquer outro tipo de movimento humano. Foi realizado um levantamento deste tipo de pesquisa em bases de dados voltadas ao tema e alguns estudos relevantes a esta pesquisa foram encontrados.

Parte dos estudos encontrados está relacionada ao reconhecimento de gestos realizados por mãos, braços ou silhueta humanos usando como base para reconhecimento do movimento a imagem do membro ou do corpo com processo de segmentação desta imagem (ABDELKADER et al., 2011; CORREA et al., 2010; NAM; WOHN, 2019; PAVLOVIC; SHARMA; HUANG, 1997; WANG et al., 2006). Valverde, Pereira e Vassalo (2011), de forma semelhante aos demais pesquisadores, utilizaram o treinamento dos MOM com um conjunto de imagens da mão considerando cinco tipos de gestos, sendo tomados 40 de cada tipo para realização do treinamento. As taxas de reconhecimento pelos MOM foram superiores a 88% em todos os casos, chegando até a 95% para um dos gestos (VALVERDE; PEREIRA; VASSALLO, 2011). Moni e Ali (2009) analisaram várias técnicas e abordagens no reconhecimento de gestos para reconhecimento de linguagem de sinais. Eles forneceram uma visão geral do MOM e seu uso em aplicações baseadas em visão, com captura de imagens usando câmeras eliminando a necessidade de sensores embutidos, tais como luvas, para rastreamento de um gesto (MONI; ALI, 2009).

Dados captados por sensores tais como acelerômetros e giroscópios podem ser utilizados para modelar um movimento com MOM. Mendes et al. (2017) utilizaram um acelerômetro para coletar dados de acelerações ao longo dos eixos *x*, *y* e *z*, bem como o tempo decorrido a uma taxa de 80 Hz para identificação dos movimentos produzidos por uma mão (MENDES et al., 2017). Chambers et al. (2002) também fizeram uso de acelerômetros para identificação de gestos. Em seu trabalho utilizaram os acelerômetros ligados ao pulso para verificação de gestos intencionais, como os executados por árbitros em partidas esportivas (CHAMBERS et al., 2002).

Sensores de captura de dados tridimensionais são bastante utilizados para reconhecimento de gestos com MOM. Gu et al. (2012), utilizaram um sensor Kinect para construção de um sistema de reconhecimento de gestos em tempo real com características obtidas a partir do modelo de esqueleto humano. Os resultados finais de sua pesquisa atingiram uma precisão média do reconhecimento de cerca de 85% (GU et al., 2012). Ghotkar, Vidap e Deo também utilizaram o sensor para o reconhecimento de gestos e atingiram uma porcentagem de 89,25% de reconhecimento (GHOTKAR; VIDAP; DEO, 2016). Osman et al. (2012) usaram em sua pesquisa o sistema de rastreamento óptico *Optotrak*. Os autores fizeram uso de um conjunto de pontos (coordenadas espaciais) para modelar trajetórias executadas por ferramentas utilizadas pelos trabalhadores de uma empresa. Os autores usam o termo “pontos chave” para se referir a pontos comuns que são encontrados em todas as trajetórias e que caracterizam os movimentos (OSMAN et al., 2017).

Gharasuie e Seyedarabi (2013) propuseram um sistema que reconhece gestos de mão a partir do movimento contínuo da mão para representação de números ingleses de 0 a 9 em tempo real, baseado em MOM. Identificaram dois tipos de gestos base: gestos-chave e gestos de ligação. Os gestos de ligação foram usados para separar os gestos de chave de outras trajetórias de movimento da mão (caminho do gesto – *spotting*). Esse é um método baseado em heurística que identifica os pontos inicial e final dos gestos principais. Então, o caminho do gesto entre esses dois pontos é dado aos MOM para classificação. Resultados experimentais mostram que o sistema proposto reconheceu com sucesso os gestos-chave com taxa de reconhecimento de 93,84% (GHARASUIE; SEYEDARABI, 2013).

A metodologia empregada pelos pesquisadores nos estudos citados nos mostra uma possibilidade de analisarmos os movimentos executados durante a realização de exercícios físicos resistidos. Os dados utilizados para verificação com

os MOM, nesta pesquisa, consistem em coordenadas cartesianas. Diferentemente de alguns pesquisadores que utilizaram coordenadas coletadas por meio de sensores infravermelhos e acelerômetros, obteve-se coordenadas apenas em vídeo e com elas foram verificados os movimentos realizados. Uma revisão mais apurada sobre o uso de coordenadas cartesianas na modelagem por MOM está descrita no próximo tópico.

2.2 Uso de modelos Markovianos com coordenadas cartesianas para modelagem de movimentos humanos: uma revisão sistemática

Na literatura científica estão presentes diversos estudos referentes ao uso de modelos Markovianos para modelagem de movimentos humanos em espaços bidimensionais. Registros gráficos produzidos por movimento de mãos humanas (grafia) foram um dos temas iniciais de pesquisas que utilizaram modelos ocultos de Markov aplicados ao reconhecimento de padrões gráficos. Inicialmente pesquisadores como Plöetz e Fink (2011) utilizaram os MOM para reconhecimento de caracteres sem levar em consideração os movimentos utilizados para o registro gráfico de caracteres redigidos manualmente. O processo utilizado por eles e muitos outros autores (ARICA; YARMAN-VURAL, 2002; FREITAS et al., 2000; EL-YACOUBI et al., 1999b; GUILLEVIC; SUEN, 1997; JUSTINO et al., 2000; KIM; GOVINDARAJU, 1998; KOERICH, 2004) para resolução do mesmo problema, está baseado na segmentação de imagens estáticas que representam caracteres redigidos manualmente sem considerar o movimento utilizado para sua elaboração.

O processo de segmentação de imagens, mesmo não tendo apresentado condições de garantir a sequência de movimentos utilizados para elaboração dos registros gráficos, nos estudos desenvolvidos pelos autores anteriormente citados, foi utilizado para identificar diferentes tipos de movimentos no trabalho de Yamato, Ohya e Ishii (1992). Os autores utilizaram a segmentação da silhueta humana em sequências de imagens para identificar diferentes jogadas em uma partida de tênis. Neste estudo é possível perceber que a segmentação de imagens pode ser utilizada para reconhecer movimentos de maior amplitude realizados por seres humanos, mas não garante que o mesmo processo sirva para reconhecimento de movimentos com menor amplitude.

Reduzir o tamanho de cada segmento de imagens pode oferecer informações mais refinadas sobre as partes constituintes do movimento em estudo. Matematicamente reduzir ao máximo a área de cada segmento de uma imagem em um processo de segmentação significa reduzir cada um destes segmentos a um ponto, ente matemático que não possui volume, área ou comprimento, ou seja reduzir a um objeto adimensional incapaz de encobrir qualquer parte de um movimento realizado por menor que ele seja. Não só o movimento pode ter uma amplitude diminuta, quanto o objeto a ter seu movimento analisado ser de tamanho mínimo, o uso de pontos para acompanhar o movimento garante a não sobreposição ou até mesmo segmentação inadequada de uma imagem. Desta forma quando se refere ao uso de pontos como marcador de um movimento prontamente se refere ao uso de coordenadas para análise deste movimento.

Estudos com uso de coordenadas para modelagem com MOM atualmente foram publicadas, considerando o espaço tridimensional, com uso de sensores de profundidade. Sensores presentes no *Kinect* pertencentes à *Microsoft*[®], por exemplo, são muito utilizados em estudos para captura de coordenadas de movimento (GHOJOGH; MOHAMMADZADE; MOKARI, 2018; HOQUE; HAQ; HASANUZZAMAN, 2019; LI et al., 2019; MOKARI; MOHAMMADZADE; GHOJOGH, 2018; SUTOPO et al., 2019). Aparelhos receptores do sistema GNSS, como os do sistema GPS, também são utilizados para análise de movimentos em espaços tridimensionais (GAO; LI; TA, 2018; OZDEMIR; TOPCU; OZDEMIR, 2018; TAGUCHI; KOIDE; YOSHIMURA, 2019; ZHU et al., 2019). Mas pouco se sabe em relação ao uso de coordenadas bidimensionais (cartesianas) na modelagem com MOM.

Dessa forma, realizou-se uma revisão de literatura de forma sistemática visando buscar estudos em que coordenadas cartesianas tenham sido utilizadas para modelagem Markoviana de movimentos realizados por seres humanos. Buscou-se com esta revisão verificar se coordenadas cartesianas forneciam dados necessários e suficientes para identificação e/ou análise de movimentos humanos em modelos Markovianos.

Métodos

Esta revisão de forma sistemática foi conduzida de acordo com as recomendações do PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) (MOHER et al., 2009) sobre a modelagem com MOM de movimentos realizados por humanos usando coordenadas cartesianas das trajetórias que descrevem o movimento. Foi realizada uma busca nas bases de dados: Pubmed (1 artigo), BVS (7 artigos) e Science Direct/Elsevier (844 artigos) usando os seguintes descritores: “HMM” AND “Coordinates” AND “Human” que resultou na escolha de nove artigos que serão apresentados a seguir (Figura 4). Esta revisão teve como objetivo verificar se MOM modelados com coordenadas cartesianas fornecem resultados satisfatórios de modelagem e reconhecimento de padrões de movimentos realizados por seres humanos.


CrITÉRIOS para seleção dos artigos

Foram incluídos nesta revisão estudos que apresentaram uso de MOM com dados de coordenadas cartesianas em seres humanos. Os critérios de inclusão adotados foram: (i) estudos completos realizados com seres humanos; (ii) publicados em língua inglesa e; (iii) nos últimos 10 anos. Os critérios de exclusão adotados foram: (i) estudos relacionados a escrita manual, assinaturas e reconhecimento de caracteres, estudos somente com dados tridimensionais, estudos relacionados a proteínas, expressões faciais, voz, coordenadas esféricas, histogramas e coordenadas polares (ii), estudos publicados em outro idioma.

Extração dos dados

Informações relevantes sobre dos estudos selecionados encontram-se no Quadro 1: 1) revista; 2) título; 3) ano; 4) identificação do autor; 5) país; 6) tecnologia usada para captura dos dados de movimento (sensor) e 7) palavras chave do estudo.

Figura 4 - Diagrama de fluxo de estudo do PRISMA.



Fonte: o autor.

Quadro 1 – Dados dos artigos utilizados na revisão.

Revista	Título	Ano	Autores	País	Sensor	Palavras - chave
Automation in Construction	Semantic trajectory insights for worker safety in dynamic environments	2019	Muhammad Arslan Christophe Cruz Dominique Ginhac	France	BLE Beacon	Semantic trajectories Building Information Modeling Stay region GPS Mobility Health and Safety Hidden Markov Model
Image and Vision Computing	Exploiting eye-hand coordination to detect grasping movements	2012	Miguel Carrasco Xavier Clady	Chile France	Digital câmera	Visual system Grasping movements Motion analysis Hand posture Hand gesture Object recognition
Medical Image Analysis	Gaze gesture based human robot interaction for laparoscopic surgery	2018	Kenko Fujii Gauthier Gras Antonino Salerno Guang-Zhong Yang	UK	Digital câmera	Robotic surgery Online calibration Gaze gestures Eye-tracking Gaze-contingent control Minimally invasive surgery
Vision Research	An inverse Yabus process: Predicting observers' task from eye movement patterns	2014	Amin Haji-Abolhassani James J. Clark	Canada	Tobii X120 eye tracker	Visual-task inference Attention cognitive model K-means clustering Visual search Eye movement Hidden Markov model
Knowledge-Based Systems	Trajectory analysis for user verification and recognition	2012	Hsing-Kuo Pao Junaidillah Fadlil Hong-Yi Lin Kuan-Ta Chen	Taiwan	Mouse	Account security Bot detection Dissimilarity measure Isomap Manifold learning On-line game Trajectory Verification
Displays	Visual rendering of shapes on 2D display devices guided by hand gestures	2019	Abhik Singla Partha Pratim Roy Debi Prosad Dogra	India	Leap Motion SDK	Gesture recognition Shape rendering Shape matching 3D rendering
Computer Vision and Image Understanding	Modeling and prediction of driver behavior by foot gesture analysis	2012	Cuong Tran Anup Doshi Mohan Manubhai Trivedi	USA	Digital camera	Gesture analysis Hidden Markov Models Optical flow Intelligent Driver Assistance Active safety Accident prevention Pedal misapplications Foot tracking Intelligent vehicle
CIRP Annals	A human modelling and monitoring approach to support the execution of manufacturing operations	2019	Marcello Urgo Marco Tarabini Tullio Tolio	Italy	Digital câmera	Man-machine system Modelling Monitoring
Pervasive and Mobile Computing	Unobtrusive assessment of stress of office workers via analysis of their motion trajectories	2019	Elena Vildjiounaite Ville Huotari Johanna Kallio Vesa Kyllönen Satu-Marja Mäkelä Georgy Gimel'farb	Finland New Zealand	Orbbec Astra Pro	Automatic detection Motion trajectories Stress Workplace

Fonte: o autor.

Resultados e Discussão.

A partir das buscas realizadas, obtiveram-se relevantes estudos referentes ao uso de coordenadas cartesianas para modelagem com MOM de movimentos humanos. Estudos de diferentes áreas, contribuem para uso dos MOM com coordenadas bidimensionais com diferentes aplicações. Alguns destes estudos levaram em consideração o movimento do ser humano como um todo, visando a análise de sua trajetória dentro de um espaço limitado, outros consideraram movimentos realizados apenas por segmentos corporais. A existência de estudos com aplicação tanto em áreas somente ligadas a tecnologia quanto em áreas de saúde preconiza o uso do modelo, alimentado por coordenadas bidimensionais, em situações que a capacidade de modelar o movimento e sua precisão é algo imprescindível. Estes diferentes estudos, com seus procedimentos e implicações, são apresentados a seguir.

Tendo por propósito rastrear trabalhadores humanos e comparar os resultados com a maneira correta de executar alguns procedimentos laborais em seu ambiente de trabalho, (URGO; TARABINI; TOLIO, 2019) obtiveram coordenadas do movimento do corpo e mãos dos trabalhadores para aplicação dos MOM. O teste foi realizado rastreando várias execuções dos mesmos procedimentos, corretos e não corretos, realizados por diferentes operadores. Conforme previsto, foram considerados dois modos de execução diferentes dos procedimentos e, para cada um deles, um MOM foi instanciado e treinado. Os resultados mostraram uma taxa de acertos pelo modelo de 73% a 100% nos casos de execuções completas do movimento.

Também visando analisar movimentos de trabalhadores, outro estudo (ARSLAN; CRUZ; GINHAC, 2019) aplicou MOM com dados bidimensionais posicionais (latitude e longitude em parte do trabalho) para analisar deslocamentos de trabalhadores em ambientes dinâmicos na construção civil. Os autores tomaram além das trajetórias percorridas pelos trabalhadores, as percorridas pelas máquinas na obra e fizeram o cruzamento destas informações relacionadas ao tempo. Os resultados obtidos mostraram que o sistema desenvolvido por eles pode ajudar a reduzir riscos de acidentes na construção civil.

De forma semelhante, analisando o movimento de trabalhadores em seu ambiente laboral, Vildjiounaite et al. (2019) propuseram um sistema de detecção de estresse personalizado e discreto, com base no uso de sensores ambientais e no

treinamento não supervisionado do classificador de MOM e, portanto, não requerendo esforços de manutenção do sensor nem de rotulagem de dados dos usuários finais. Os autores partiram da suposição de que o comportamento de um indivíduo em um estado estressado se desvia do seu comportamento no estado normal e, portanto, um modelo de comportamento normal deve ajudar a detectar desvios comportamentais. Os rótulos de estresse, relacionados a seus comportamentos em ambiente de trabalho (deslocamentos e saídas de seus escritórios) foram adquiridos solicitando aos sujeitos que relatassem todos os dias como "muito estressantes", "estressantes" ou "normais". Nos experimentos coletados durante 10 meses, o sistema proposto alcançou 67% de precisão na classificação diária como estressante versus normal e 95% de precisão na classificação nos meses, graças à descoberta de novas características das trajetórias de movimento, indicativo de estresse (VILDJOUNAITE et al., 2019).

Três outros estudos apresentam o uso de coordenadas cartesianas para mapear os movimentos realizados pelo olho humano. Em um destes estudos, os autores (CARRASCO; CLADY, 2012) propõem uma nova abordagem para detectar movimentos de preensão de objetos por meio de técnicas de visão computacional. Esta solução funde dois pontos de vista, um ponto de vista obtido de um rastreador ocular que captura a perspectiva do usuário e um segundo ponto de vista que é capturado por uma câmera vestível conectada ao pulso do usuário. O método proposto pode prever movimentos de preensão do usuário, bem como o objeto alvo na cena, fundindo dois canais de informação. A partir das informações desses dois pontos de vista, os autores conseguiram caracterizar vários movimentos das mãos em conjunto com os movimentos dos olhos por meio dos MOM. O modelo proposto obteve uma taxa de reconhecimento dos movimentos de 80% a 90%.

Em outro estudo, os autores (FUJII et al., 2018) apresentam um sistema robótico no qual um endoscópio rígido mantido por um braço robótico é controlado pelo movimento ocular de um médico cirurgião, excluindo a necessidade de um assistente de câmera. Gestos de olhar detectados através de uma série de movimentos oculares são usados para transmitir a intenção do cirurgião em movimentar o braço robótico. MOM foram usados no reconhecimento de gestos em tempo real, permitindo que a câmera robótica realizasse as movimentações necessárias. Coordenadas bidimensionais das trajetórias de um gesto (olhar) foram agrupadas usando o algoritmo de agrupamento de dados *k-means*. O número de símbolos de cada agrupamento, as coordenadas do centroide de cada agrupamento

(cluster) e o raio foram usados coletivamente para criar um banco de códigos discretos que detinham os recursos relevantes dos gestos de olhar, ou seja, as coordenadas x e y . Cada sequência de gestos de olhar em potencial foi codificada usando um banco de códigos, onde os símbolos foram atribuídos a cada observação (coordenadas x e y) usando a distância entre a observação e o centroide de cada cluster, desde que estivesse dentro do raio definido. Se uma observação estivesse fora do raio definido, ela era descartada. A média geral para reconhecimento de gestos baseados em MOM foi de 96,48%, com uma taxa de falsos positivos média de 1,17%. Os resultados mostraram a eficiência e segurança do uso de MOM para o controle robótico baseado em gestos. A metodologia aplicada pelos autores tem muitos pontos semelhantes ao desta tese.

Haji-Abolhassani e Clark (2014) desenvolveram um método probabilístico para inferir a tarefa visual de um espectador, dadas as trajetórias medidas de movimento ocular obtidas por meio de rastreamento de coordenadas bidimensionais. Este método é baseado na teoria dos modelos de MOM, que emprega um processo de Markov de primeira ordem (no qual a transição para o próximo estado depende somente do estado atual) para prever os movimentos oculares. A técnica foi aplicada em um conjunto de dados constituído de trajetórias de movimentos oculares obtidas de sujeitos que visualizaram imagens monocromáticas de cenas reais e submetidas a perguntas sobre as cenas. Os resultados mostraram que a abordagem, combinada com uma técnica de agrupamento (*k-means*), pode ser uma maneira confiável de inferir tarefas visuais a partir de dados de movimentos oculares (HAJI-ABOLHASSANI; CLARK, 2014).

Em outro trabalho, referente ao reconhecimento de gestos, os autores (SINGLA; ROY; DOGRA, 2019) propõem uma metodologia baseada no sensor *Leap Motion*⁹ para facilitar a renderização de formas 2D e 3D em dispositivos de exibição. O método proposto rastreia os movimentos dos dedos enquanto os usuários realizam gestos naturais dentro do campo de visão do sensor de movimento. Em seguida, as trajetórias são analisadas e fornecem dados para treinamento dos MOM (da esquerda para a direita). É proposto um mapeamento individual entre gestos e formas. Foi criado um conjunto de dados com as amostras gravadas por 10 voluntários. O conjunto de

⁹ Para mais informações sobre o dispositivo acesse: <https://developer.leapmotion.com/#101>

dados foi formado por 18 formas geométricas e 18 não-geométricas. O método proposto atingiu precisão de reconhecimento de gestos de até 98,22%.

A análise de trajetórias também está presente no estudo de Pao et al. (2012). Neste artigo, os autores propuseram uma abordagem geral de verificação do usuário (informática) com base em trajetórias produzidas por eles no uso do microcomputador. A referida trajetória consiste em uma sequência de entradas coordenadas bidimensionais. Foram analisados diferentes tipos de trajetórias, incluindo rastros de jogos on-line, de mouses e de movimentos de animais em seus ambientes naturais. Especificamente, a metodologia desenvolvida concentrou-se em encontrar os padrões ocultos incorporados nas trajetórias produzidas pelos usuários. Os autores utilizaram um modelo de cadeia de Markov com uma distribuição gaussiana em sua transição para descrever o comportamento da trajetória. Para distinguir entre duas trajetórias, eles introduziram uma nova medida de dissimilaridade combinada com uma variedade de técnicas de ajuste aprendidas para capturar a relação pareada entre as duas trajetórias. Os resultados demonstraram que o método proposto pode ter um desempenho melhor ou ser competitivo com as abordagens de ponta existentes, tanto para as tarefas de verificação quanto de reconhecimento (PAO et al., 2012).

Em outro estudo, os movimentos de membros inferiores do corpo humano foram rastreados. Os autores (TRAN; DOSHI; TRIVEDI, 2012) propuseram e desenvolveram uma estrutura baseada em visão para análise do comportamento do pé de motoristas usando rastreamento óptico com obtenção de coordenadas bidimensionais. Usaram os MOM para caracterizar o comportamento produzido pelo movimento do pé. No experimento foi utilizado um banco de ensaio de condução no mundo real e também foram utilizados modelos de comportamento do pé com MOM para prever pressões nos pedais de aceleração e de freio. Os resultados experimentais em diferentes sujeitos forneceram alta precisão (94% em média) tanto para a inferência do estado do comportamento do pé quanto para a previsão do pressionamento do pedal.

Yamada et al. (2013) realizaram um estudo cujo objetivo foi propor um método original que permitisse o reconhecimento de um movimento oscilante. Foi utilizado um sistema de captura de movimento óptico para monitorar o movimento de um ser humano. Os dados capturados foram transformados em séries de símbolos. A sequência de símbolos foi aprendida e reconhecida por MOM. Uma avaliação foi realizada com cinco pessoas. Os movimentos foram a rebatida e o arremesso de uma

bola de beisebol e as ações motoras do tênis. A precisão da avaliação com o conjunto de dados foi de mais de 80% de reconhecimento (YAMADA et al., 2013).

Considerações Finais

O uso de coordenadas cartesianas como descritoras de trajetórias de deslocamentos de pontos de interesse (no tempo e/ou espaço) ainda é um método atual de estudos, tendo em vista que mais da metade dos estudos selecionados foi publicado nos últimos cinco anos. O uso de coordenadas permite melhor observação do movimento de articulações ou segmentos corporais pela seleção de áreas de interesse sem sobreposições, que podem ocultar parte do movimento. Além disso, dispositivos atuais, fornecem coordenadas de deslocamentos em formatos comuns para análise, o que favorece seu uso para obtenção de dados posicionais.

O uso de câmeras digitais esteve presente na metodologia de quatro dos nove artigos, sendo dois deles publicados nos últimos dois anos. Isso mostra que o uso de câmeras digitais para análise de movimentos é apropriado para realização deste tipo de estudo. Outro ponto de destaque nesta revisão é o uso do algoritmo de agrupamento *k-means*. Este método de agrupamento de dados, por meio do cálculo de distâncias euclidianas, também apresentou resultados satisfatórios para análise do movimento bidimensional quando empregado em conjunto à modelagem markoviana.

Nos estudos selecionados foi possível perceber que a captação de dados bidimensionais do movimento humano (coordenadas cartesianas) forneceu dados suficientes para modelagem com MOM das trajetórias descritas por estes movimentos. Os resultados obtidos apresentaram taxas de reconhecimento compatíveis com as necessidades dos estudos para análise da trajetória, o que leva a entender que uso de uma base de dados bidimensionais pode fornecer resultados confiáveis para análise do movimento com MOM.

2.3 Movimentos na execução de exercícios físicos

Em treinamento de força, deve-se ter um planejamento adequado dos tipos de exercícios para obtenção de resultados satisfatórios no que tange ao aumento de força muscular, potência e resistência muscular localizada. Outros ganhos funcionais, como aumentos na coordenação, na agilidade, no equilíbrio e na velocidade, também são objetivos comuns de programas de condicionamento com exercícios resistidos

(FLECK, 1999). A realização de exercícios monoarticulares e multiarticulares, ambos para uma mesma musculatura, é uma prática muito comum que traz benefícios ao treinamento resistido (AUGUSTSSON et al, 2003; GENTIL et al, 2007; TAN, 1999; SALLES et al, 2008).

Exercícios monoarticulares são caracterizados por movimentos mais simples, envolvendo uma única articulação e um menor número de músculos (BAECHLE; EARLE, 2008) que são bastante exigidos durante a suspensão de cargas. Durante o movimento de braços, por exemplo, forças inerciais criam mudanças no torque em várias articulações do corpo, incluindo as envolvidas no controle postural (LATASH, 1998). Mesmo que nos exercícios monoarticulares a força produzida seja direcionada principalmente alinhada ao segmento corporal (HALL, 2016), com o aumento da carga, em uma barra durante um exercício de rosca direta, pode ocorrer desestabilização postural alterando a projeção do centro de gravidade do corpo (DUARTE, 2000). Os exercícios multiarticulares, diferentemente dos monoarticulares, requerem um padrão de movimento mais complexo, devido à interação de diferentes torques musculares sendo gerados em duas ou mais articulações (SCOTT, 2000).

Os exercícios monoarticulares são mais fáceis de se executar, pois necessitam de menor coordenação neuromuscular e por isso devem ser executados somente ao final da sessão de treino (KRAEMER; RATAMESS 2004). A realização de exercícios multiarticulares precedendo exercícios monoarticulares possibilita aumento do volume de treinamento, permitindo que exercícios mais complexos, que precisam de maior coordenação neuromuscular e maior ativação do sistema nervoso sejam sempre realizados no início da seção de treinamento (RHEA et al. 2003). A combinação de exercícios mono e multiarticulares é benéfica no treinamento resistido. Músculos monoarticulares possuem alta capacidade de produção de força ou trabalho enquanto que os multiarticulares têm a função de distribuir o torque para todas as articulações envolvidas e controlar a direção do movimento (JACOBS; VAN INGEN SCHENAU, 1992).

Exercícios monoarticulares estressam apenas um único grupo muscular, enquanto exercícios multiarticulares estressam mais de um grupo muscular. Os monoarticulares proporcionam aumento da força muscular nos grupos musculares alvo e apresentam nível reduzido de habilidades e técnicas envolvidas. Exercícios multiarticulares envolvem uma ativação e coordenação neural mais complexa e, devido ao maior envolvimento da massa muscular (e subsequente quantidade de peso

utilizada), geralmente são considerados mais eficazes para aumentar a força de um maior grupo muscular (KRAEMER; HAKKINEN, 2004).

Músculos multiarticulares possuem propriedades funcionais de controle da direção do movimento e da força enquanto que os músculos monoarticulares apresentam a função de geração de força (JACOBS; VAN INGEN SCHENAU, 1992). Desta forma a inserção de exercícios mono e multiarticulares em um planejamento de treinamento de força é imprescindível tanto para obtenção de ganho de força e massa muscular quanto para obtenção de outros ganhos funcionais associados importantes para uma boa qualidade de vida. Neste tópico são abordadas as formas de execução dos exercícios mono e multiarticulares que fazem parte deste estudo.

2.3.1 Exercício monoarticular: rosca direta com barra

Este é um exercício monoarticular voltado ao desenvolvimento da força dos músculos flexores do cotovelo. Deve-se cuidar para não flexionar o tronco durante a realização do exercício. Para evitar lesões, deve-se manter as costas em uma posição neutra e flexionar os joelhos levemente durante a execução do exercício. Escorar as costas na parede ajuda a mantê-las retas. Pode-se utilizar um cinto para treinamento de força caso a carga seja alta.

O exercício rosca direta é realizado em um plano sagital e neste plano ocorrem os movimentos para frente e para trás do corpo dos segmentos corporais. Os músculos atuantes no movimento de flexão de cotovelo durante a execução do exercício são: direta braquial, braquial e braquiorradial (estes são os principais); flexor radial do carpo, flexor ulnar do carpo, palmar longo, pronador redondo e flexor superficial dos dedos, (estes são os secundários) (HALL, 2009).

O Quadro 2 apresenta as formas de alinhamento, posicionamento e execução dos exercícios de rosca direta com barra.

Quadro 2 – Postura e técnica de execução de rosca direta com barra.

	Rosca direta com barra
Alinhamento e posicionamento	Deve-se agarrar a barra de forma equilibrada, empunhadura fechada e supinada.
	A largura da empunhadura deve ser de tal forma que os braços toquem as laterais do tronco ou dos quadris e os dedos mínimos toquem as coxas.
	Os pés devem estar afastados na largura dos ombros ou dos quadris com os joelhos levemente flexionados, troco ereto, ombros para trás e olhar para frente.
	A barra deve ficar suspensa com a extensão total dos cotovelos.
Técnica de execução	No movimento ascendente a barra deve ser levantada descrevendo um arco a partir da flexão dos cotovelos. Os punhos devem permanecer rígidos e os braços imóveis contra a lateral do tronco. Nenhum movimento deve ocorrer nos ombros. O corpo não deve balançar, os ombros não devem subir, nem se deve elevar os pés. Os cotovelos devem ser flexionados até que a barra se aproxime da parte clavicular deltoide.
	No movimento descendente a barra deve ser abaixada controladamente até a posição inicial com a extensão total dos cotovelos. Tronco não deve ser flexionado. Punhos, joelhos e pés devem permanecer como na posição inicial.

Fonte: Adaptado (NSCA, 2010).

A Figura 5 exibe a forma de execução do exercício de rosca direta descrito no Quadro 02.

Figura 5 - Posicionamento e execução do exercício de rosca direta com barra. A - Posição inicial com vista frontal. B - Posição inicial com vista lateral. C - Movimento ascendente do exercício com vista frontal. D - Movimento ascendente com vista lateral.



Fonte: Adaptado (CHANDLER; BROW, 2009).

2.3.2 Exercício multiarticular: agachamento livre com barra

De forma geral o exercício de agachamento, que pode ser realizado com o peso do próprio corpo ou com carga, é um exercício de deslocamento multiarticular projetado para trabalhar com os músculos do quadril e das coxas. O agachamento realizado somente com o peso do corpo fornece grande parte dos benefícios de outros tipos de agachamento, mas não requer que a pessoa utilize carga sobre os ombros ou diretamente sobre a coluna. Ele também é considerado um exercício mais funcional do que outras atividades elaboradas para as pernas pois reproduz movimentos comuns como os de sentar e levantar (AABERG, 2001).

Conforme o autor, seguem algumas observações para realização do exercício:

- O peso corporal (com ou sem carga) deve estar apoiado nos tornozelos e deve-se evitar erguer os calcanhares do chão;
- Deve-se manter os joelhos alinhados com os pés;
- Não se deve agachar mais do que o ponto em que a coxa forma um ângulo de 90° com a perna ou onde os joelhos ultrapassam os dedos dos pés.
- Deve-se manter os ombros para trás, a curvatura natural da coluna lombar e a cabeça e o pescoço em posição neutra durante todo o exercício.

O Quadro 3 apresenta as formas de alinhamento, posicionamento e execução dos exercícios de agachamento livre com carga usando barra.


Quadro 3 – Postura e técnica de execução de agachamento livre com barra.

	Agachamento livre com barra
Alinhamento e posicionamento	Fique em pé em posição de prontidão. Coloque a barra sobre as escápulas, acima do músculo trapézio.
	Coloque as pernas um pouco além da linha dos ombros e gire os quadris e os pés para fora cerca de 20º a 30º.
	Comece com os quadris e joelhos flexionados, o tronco ligeiramente inclinado para a frente, a coluna em posição de prontidão e o peso do corpo apoiado nos tornozelos.
Técnica de execução	Flexione os joelhos. Comece a abaixar o corpo lentamente, apenas até o ponto onde as coxas formam um ângulo de aproximadamente 90º com as pernas ou enquanto você conseguir manter a curvatura natural da coluna lombar.
	Mantenha a posição e continue contraindo os glúteos, quadríceps e posteriores da coxa, enquanto estabiliza o corpo com o tronco.
	Contraia os glúteos e os posteriores da coxa. Comece a estender as pernas lentamente, mantendo o peso sobre os tornozelos.
	Estenda as pernas de volta à sua posição inicial, sem perder o posicionamento correto da coluna.

Fonte: Adaptado (AABERG, 2001).


As Figuras 6, 7 e 8 exibem as formas de agachamento descritas no Quadro 01 e no Manual de Técnicas de Exercício para Treinamento de Força (NSCA, 2010).

Figura 6 - Posicionamento para execução do exercício de agachamento com carga em barra.




Fonte: Adaptado (NSCA, 2010).

Figura 7 - Posições do movimento descendente na execução do exercício de agachamento livre com barra.



Fonte: Adaptado (NSCA, 2010).

Figura 8 - Posição final do movimento ascendente na execução do exercício de agachamento livre com barra.



Fonte: Adaptado (NSCA, 2010).

2.3.3 Execução de habilidades motoras

Os movimentos realizados durante a execução de exercícios físicos podem ser compreendidos pela definição geral de movimentos de Magill (2011) como “características comportamentais de membros específicos ou uma combinação de membros que são partes constituintes de uma ação ou habilidade motora” (MAGILL, 2011, p 29). Esta habilidade mencionada pelo autor, está relacionada a atividades ou tarefas com finalidades específicas ou objetivas e que ainda pode ser um indicador da qualidade de desempenho. As habilidades são em geral caracterizadas por movimentos mais complexos e refinados, que são alcançados pelo aprendizado (SCHMIDT; WRISBERG, 2010; SINGER, 1975).

Movimentos oriundos de atividades esportivas ocorrem em função da natureza complexa dos multi-elementos que interferem na sua composição. Desta forma, procura-se definir métodos e princípios biomecânicos para identificar e analisar o movimento e assim verificar o comportamento e os efeitos dos mecanismos motores dos movimentos (AMADIO; DUARTE, 1996). A compreensão biomecânica da habilidade desenvolvida pelo atleta, com a identificação de possíveis erros na execução de movimentos, traz benefícios ao atleta e pode ajudar na melhoria de seu desempenho.

Embora a maioria dos movimentos humanos possam ser executados usando uma variedade de trajetórias ou órbitas limitadas às restrições biomecânicas, os movimentos humanos exibem padrões significativos e os desvios dos padrões destes movimentos podem ser utilizados para avaliar a saúde, habilidade ou desempenho do executor. A trajetória descrita por um movimento é o resultado de um processo de otimização sob uma combinação de restrições como eficiência, segurança e habilidade (HAGLER, 2016). Neste sentido, analisar a trajetória percorrida por um determinado membro ou articulação pode fornecer informações importantes sobre a execução do movimento.

As propriedades topológicas do movimento do corpo e dos membros especificam a percepção de uma determinada atividade. Em outras palavras, a categorização de qualquer atividade é determinada pelas características invariantes dos movimentos do corpo e dos membros que a constituem. Sendo assim, pode-se propor que cada atividade física seja definida por um conjunto único de propriedades topológicas de movimentos (NEWELL, 1985).

A categorização da ação é baseada principalmente no padrão de coordenação definido pelos membros ou segmentos dos membros. Nessas ações, o movimento de membros individuais ou segmentos de membros definem a coordenação. O controle do padrão de coordenação é outra característica nas tomadas de decisão sobre a qualidade do padrão de movimento. Desta forma, a avaliação do padrão de movimento envolve duas tarefas: determinar a forma ou topologia do padrão de movimento, conforme definido pela coordenação, e avaliar seu controle (SPARROW; SHERMAN, 2001).

É necessário avaliar a execução do movimento antes de iniciar uma atividade física que exija esforço, pois a capacidade de se mover fornece a base para a capacidade de realizar atividades de condicionamento físico, tarefas de trabalho e atléticas e atividades básicas da vida diária. É importante ser capaz de distinguir o movimento disfuncional do movimento tomado como normal; também é importante reconhecer que o treinamento com padrões de movimento inadequados reforça a má qualidade do movimento e provavelmente aumenta o risco de lesão e predispõe a maiores níveis de disfunções (HOOGENBOOM; VOIGHT; COOK, 2012).


Para avaliar o desempenho em uma atividade física, é necessário comparar os desempenhos observados com algum modelo padrão. No entanto, como não há um modelo ideal geral, torna-se necessário ter um modelo apropriado para quem está sendo avaliado. Sendo assim, o modelo precisa de especificidade individual. Isso claramente requer a identificação prévia de características no estágio de preparação. Além disso, padrões incorretos do movimento podem ser identificados por meio de características deste movimento tais como a própria amplitude de movimento articular (BARTLETT, 2007). Neste sentido, os MOM podem fornecer informações importantes sobre o movimento a partir da análise das trajetórias percorridas pelo corpo, articulações, membros ou seus segmentos.

Como já mencionado, alterações do padrão de movimento na realização de um exercício físico devem ser detectadas e consideradas a fim de se prevenirem lesões e melhorar o desempenho. Estas alterações podem ser oriundas, além de outros fatores, do uso inadequado de carga para realização de um exercício físico. O estudo realizado por Mckean e seus colaboradores apontou a alteração de padrões do movimento com o acréscimo de carga em um exercício de agachamento. Os resultados do estudo mostraram que, à medida que as cargas aumentavam, os ângulos dos quadris e joelhos dos participantes também aumentavam, para acomodar

as cargas, alterando os ângulos relativos dessas articulações (MCKEAN; DUNN; BURKETT, 2010). No caso de exercícios de rosca, o movimento de todo o braço em torno da articulação do ombro a partir da posição de referência anatômica é chamado de flexão, e seu retorno a essa posição é chamado de extensão (BARTLETT, 2007). O termo 'flexão' refere-se a uma diminuição do ângulo articular no plano sagital, enquanto 'extensão' é o movimento que aumenta o ângulo articular (KNUDSON, 2007).

O plano sagital, mencionado anteriormente, é um plano vertical que passa da parte traseira (posterior) para a frente (anterior), dividindo o corpo em metades esquerda e direita (Figura 9). Também é conhecido como plano anteroposterior. A maioria dos movimentos esportivos e de exercícios quase bidimensionais, como corrida e salto em distância, ocorrem neste plano (BARTLETT, 2007). Desta forma o uso de ferramentas de análise bidimensional, com informações contidas apenas do plano sagital, pode ser suficiente para caracterização e análise dos padrões de movimentos de flexão e extensão.

Figura 9 - Representação de um plano sagital.



Fonte: Adaptado (PINTEREST, 2020).

Piret e Béziers (1992) em seus estudos pressupõem que a coordenação motora é a organização da execução do ato motor que permite obter um equilíbrio entre os grupos musculares antagonistas organizados pelos músculos biarticulares, denominados como músculos condutores que trabalham em sinergia com os músculos monoarticulares. Então, a partir do pressuposto das pesquisadoras, em um

exercício de rosca direta a máxima eficiência obtida pelo membro superior para força e coordenação ocorre quando o ângulo do cotovelo atinge cerca de 45° de flexão que corresponde ao momento ótimo de trabalho para a musculatura que cruza a articulação do cotovelo e que tem uma ação antagonista (BORGES, 2009). Conforme Piret e Béziers essa é a posição de coordenação. Reunir força e equilíbrio é a melhor condição para o trabalho muscular (PIRET e BÉZIER, 1992).

Já a determinação das forças internas dos músculos e articulações é um problema metodológico para biomecânica, que se constitui em base fundamental para melhor compreensão de critérios para o controle de movimento (CHAO, 1986). O controle e sincronização de movimentos dos diferentes segmentos corporais e o controle de suas trajetórias têm direta relação com o controle de força e o equilíbrio mecânico (GEORGE, 1980). A aplicação de sobrecarga, na realização de exercícios resistidos, pode influenciar a coordenação na realização de movimentos como já visto em alguns estudos (MCKEAN; DUNN; BURKETT, 2010). Desta forma, espera-se que MOM sejam capazes de identificar estas alterações de coordenação motora influenciadas pela sobrecarga por meio de mudanças nas trajetórias dos movimentos executados.

3 JUSTIFICATIVA

O uso de tecnologias para identificação da qualidade de execução de movimentos humanos, principalmente no que se refere à capacidade de detectar erros biomecânicos na realização dos movimentos, pode ser uma valiosa ferramenta para profissionais da área de Educação Física. Grande parte das avaliações realizadas por esses profissionais baseia-se na observação dos movimentos realizados pelos alunos durante a execução de atividades físicas. Cabe, então, ao profissional de Educação Física, geralmente por meio de uma avaliação qualitativa do movimento, detectar a existência de erros e, se possível, realizar um procedimento de intervenção visando diminuir o risco de lesões e melhorar o desempenho de seu aluno. Para uma intervenção adequada, necessita-se de uma avaliação eficaz, capaz de identificar os déficits encontrados nas disfunções do aluno.

Neste sentido os modelos ocultos de Markov podem contribuir significativamente para o reconhecimento de alterações na realização de movimentos na realização de atividades físicas. Por isso neste trabalho busca-se verificar se os MOM são capazes de identificar alterações significativas de deslocamentos articulares na realização de exercícios físicos que podem indicar erros biomecânicos durante sua execução e que podem colocar em risco a saúde do praticante. A hipótese que pretendemos demonstrar é a de que o uso dos MOM pode tornar a avaliação de um movimento durante a realização de um exercício físico mais rápida, e até mesmo ser capaz de identificar erros biomecânicos imperceptíveis ao observador humano.

4 OBJETIVOS

4.1 Objetivo geral:

Analisar se os modelos ocultos de Markov são capazes de identificar variações da posição do eixo articular durante o movimento mono e multiarticular ao comparar a execuções sem e com a adição de cargas externas.

4.2 Objetivo específico:

1) Modelar, por meio de modelos ocultos de Markov, a execução de movimentos humanos realizados durante exercícios mono e multiarticulares.

2) Verificar se os MOM, treinados com coordenadas de imagem sem dados de mensuração ou calibração do ambiente reconhecem alterações previamente estabelecidas da execução de movimento de exercícios mono e multiarticulares.

3) Verificar o potencial de análise de MOM ao comparar a capacidade em identificar alterações da execução de movimentos de exercícios mono e multiarticulares, com a avaliação humana experiente.

5 HIPÓTESES

Primeiro Teste

H_0 = Modelos Ocultos de Markov não são capazes de identificar perturbações do movimento na execução de exercícios mono e multiarticulares devidas a alteração de carga;

H_1 = Modelos Ocultos de Markov são capazes de identificar perturbações do movimento na execução de exercícios mono e multiarticulares devidas a alteração de carga.

Segundo Teste

H_0 = MOM não necessitam de dados de mensuração ou calibração do ambiente para reconhecer alterações previamente estabelecidas da execução de movimentos de exercícios mono e multiarticulares;

H_1 = MOM necessitam de dados mensuração ou calibração do ambiente para reconhecer alterações previamente estabelecidas da execução de movimentos de exercícios mono e multiarticulares.

Terceiro Teste

H_0 = MOM não podem identificar alterações da execução de movimentos de exercícios mono e multiarticulares, não perceptíveis a avaliadores humanos experientes;

H_1 = MOM podem identificar alterações da execução de movimentos de exercícios mono e multiarticulares, não perceptíveis a avaliadores humanos experientes.

6 MÉTODOS

Sujeitos

Participaram do estudo dez voluntários todos indivíduos do sexo masculino, por meio de amostragem por conveniência, com idade: $26 \pm 4,9$ anos, altura: 177 ± 8 cm, peso corporal: 86 ± 16 kg. Todos os voluntários tinham experiência mínima de 6 meses na realização de exercícios de rosca direta com barra e agachamento livre com barra. Foi tomado como critério de exclusão a inaptidão na realização de algum dos exercícios propostos.

Procedimentos

Todos os participantes consentiram voluntariamente com o estudo por meio da assinatura do Termo de Consentimento Livre e Esclarecido - TCLE protocolado no Comitê de Ética em Pesquisa com Seres Humanos da Faculdade de Ciências da Unesp, campus de Bauru (CAEE: 17486119.0.0000.5398).

A coleta dos dados foi realizada no Laboratório de Otimização do Rendimento Esportivo Humano - LABOREH da Unesp, Campus Bauru. O espaço destinado à execução dos exercícios resistidos foi de aproximadamente 5 m de comprimento por 2,4 m de largura e 2,9 m de altura. O espaço contava com piso emborrachado, antiderrapante, cor preta fosca e paredes laterais pintadas na cor branca. O plano de fundo foi montado com tecido preto fosco com marcadores quadrados na cor verde para calibração do sistema (Figura 10).

Nos participantes foram utilizados marcadores semiesféricos em poliestireno expandido (EPS) branco, pintados de cor verde, medindo 25 mm de diâmetro, montados por sistema de marcas anatômicas, fixados na pele e roupa dos participantes com esparadrapo hipoalergênico (Figura 11). Diferentemente dos marcadores de calibração, a forma semiesférica foi escolhida para os marcadores aplicados nos participantes devido à projeção do centro da semiesfera coincidir com o centro do círculo correspondente na imagem, o que tende a reduzir erros de perspectiva. A vestimenta usada pelos participantes variou, mas foi solicitado não usar roupas em tons de verde para manter o contraste com os marcadores.

Figura 10 - Espaço destinado a realização dos exercícios.



Fonte: o autor.

Figura 11 - Fixação de marcadores semiesféricos de cor verde nos participantes.



Fonte: o autor.

A representação das articulações e pontos de interesse no caso do exercício de agachamento foi realizada mediante um modelo constituído de quatro marcadores anatômicos dispostos da seguinte forma: maléolo lateral esquerdo, côndilo lateral do joelho esquerdo, trocânter maior do fêmur esquerdo e extremidade da barra (Figura 12) doravante denominados respectivamente por tornozelo, joelho, quadril e barra. No caso do exercício de rosca direta com barra o modelo foi constituído por três marcadores fixados nas regiões do tubérculo maior do úmero direito, epicôndilo lateral do úmero direito e extremidade da barra (Figura 13) doravante denominados respectivamente por ombro, cotovelo e barra.

Figura 12 - Localização dos marcadores no corpo do participante para o exercício de agachamento livre com barra.



Fonte: o autor.

Figura 13 - Localização dos marcadores no corpo do participante para o exercício de rosca direta com barra.



Fonte: o autor.

O ambiente foi apresentado aos voluntários e foram passadas orientações de execução dos exercícios de rosca direta com barra e agachamento livre com barra com base no Manual de Técnicas de Exercício para Treinamento de Força (NSCA, 2010). Os voluntários para realização do exercício de rosca direta com barra iniciaram com uma sequência de três repetições completas de rosca direta somente com a barra (considerada condição de referência por oferecer carga mínima). Logo após uma pausa de cinco minutos de descanso realizaram mais três repetições do exercício com carga (uso da barra com anilhas) de 25% de seu peso corporal (VANDERBURGH; MAHAR; CHOU, 1995) e depois de mais uma pausa outras três repetições de rosca direta com barra com carga de 50% de seu peso corporal.

Os voluntários para realização dos exercícios de agachamento livre com barra, executaram os exercícios iniciando com uma sequência de três repetições completas de agachamento somente com a barra (considerada condição de referência por oferecer carga mínima). Logo após cinco minutos de descanso realizaram mais três repetições de agachamento com carga com 50% de seu peso corporal e depois de

YANG et al., 2017; ZIMMERMANN et al., 2017), e o tempo de aquisição do vídeo foi correspondente ao de três execuções do respectivo exercício para cada carga.

Após a obtenção dos vídeos houve o processamento digital no qual foi utilizado o editor de vídeos Wondershare Filmora versão 9 (WONDERSHARE, 2019) para aplicação de efeito *Chroma Key* (VAN DEN BERGH; LALIOTI, 1999) sobre a cor dos marcadores e aplicação do canal Alfa (MATLANI; SHRIVASTAVA, 2019) para melhor contrastar os marcadores com o resto do ambiente na cena (Figura 15).

Figura 15 - Exemplo de aplicação de filtros nos vídeos. Em A está a imagem do vídeo original. Em B exibe a aplicação do efeito *Chroma Key* que localiza e altera a cor dos marcadores. E em C está a aplicação do canal Alfa que subtrai praticamente tudo que não foi selecionado pelo *Chroma Key*.




Fonte: o autor.

Logo após foi utilizado o *software* Kinovea 0.8.27 (KINOVEA, 2019) para reconhecimento e denominação dos marcadores (de forma manual) de acordo com a ordem predefinida pelo operador. Em seguida a ferramenta de rastreamento no *software* Kinovea foi acionada para se obter o modo semiautomático de captação das coordenadas dos marcadores (Figura 16).


Os dados de posicionamento cartesiano e tempo foram exportados para arquivos do tipo *Extensible Markup Language* – XML. A origem do sistema de coordenadas cartesianas foi atribuída ao centro de um dos marcadores semiesféricos e recalibrada a cada uma das execuções de cada exercício (Figura 17).

Figura 16 - Trajetória descrita por cada marcador durante a realização de um exercício de rosca direta com barra. Rastreamento obtido com o software Kinovea.



Fonte: o autor.

Figura 17 - Tela de escolha da origem do sistema de coordenadas e calibração do Kinovea.



Fonte: o autor.

Obtenção de medidas de deslocamento

Foram tomadas as medidas de deslocamento dos marcadores para cada exercício. No exercício de rosca direta com barra dos marcadores localizados no tubérculo maior do úmero direito (ombro), epicôndilo lateral (cotovelo) foram obtidos os deslocamentos radiais por meio da fórmula para cálculo de distâncias euclidianas:

$$d = \sqrt{(x_f - x_i)^2 + (y_f - y_i)^2} \quad (33)$$

em que d é o valor do deslocamento, (x_f, y_f) é a coordenada do ponto final do deslocamento e (x_i, y_i) é a coordenada do ponto inicial do deslocamento do marcador.

O deslocamento do marcador localizado na barra (referente ao punho) assim como todos os demais inseridos para o exercício de agachamento tiveram os deslocamentos calculados pela sua variação em relação ao eixo y:

$$\Delta = y_f - y_i \quad (34)$$

em que Δ é o deslocamento, y_f é o valor em y da coordenada no ponto final e y_i é o valor em y da coordenada no ponto inicial. As fórmulas para os cálculos de distâncias foram implementadas na planilha eletrônica *Microsoft® Excel* 2016.

Tratamento estatístico dos dados

A análise estatística foi realizada com uso do programa SPSS® (*Statistical Package for Social Science*) versão 18.0.0 (IBM, 2019). Realizou-se análise de variâncias ANOVA *One Way* para verificar a existência de diferenças significativas de deslocamento, obtido durante a fase ascendente dos exercícios, de acordo com as diferentes cargas utilizadas. Foram utilizadas as medidas de deslocamento máximo de cada marcador (em cada execução) para os diferentes valores de carga de cada exercício. Foi utilizado o teste *post-hoc* de *Tukey* com nível de significância $p < 0,05$.

Para os resultados oriundos dos avaliadores humanos, foram analisados os percentuais de concordância (respostas em consonância) entre modelo estatístico e cada avaliador e entre avaliadores. Também foi realizada uma análise estatística da confiabilidade inter avaliadores utilizando o valor do coeficiente *Kappa* de Cohen (para dados dicotômicos). O Coeficiente *Kappa* pode ser definido como uma medida de associação usada para descrever e testar o grau de concordância entre os avaliadores (KAFADAR et al., 2006).

A interpretação dos resultados do teste estatístico Kappa de Cohen foi realizada conforme os intervalos estabelecidos por Landis e Koch conforme mostra o Quadro 4 (LANDIS; KOCH, 1977).

Quadro 4 - Valores para interpretação dos resultados da estatística Kappa.

Kappa	Concordância
< 0,00	Pobre
0,00 a 0,20	Fraca
0,21 a 0,40	Aceitável
0,41 a 0,60	Moderada
0,61 a 0,80	Substancial
0,81 a 1,00	Quase perfeita

Fonte: (LANDIS; KOCH, 1977).


Análise dos padrões pelos MOM

Os resultados obtidos pela ANOVA, que apresentaram diferenças significativas de deslocamento para algumas articulações e pontos de interesse, pela análise em grupo, forneceram o critério para que dados de posicionamento destes marcadores fossem processados pelos MOM. Os algoritmos do modelo markoviano (GHAHRAMANI, 2019; GONZÁLEZ, 2012; HERTA, 2019; MATHWORKS, 2019) foram implementados e executados em linguagem de alto nível para computação numérica com o *software* GNU Octave 4.2.1 (GNU OCTAVE, 2019). Para execução desta análise foram fornecidos aos MOM dados bidimensionais referentes à trajetória percorrida de cada marcador, descrita durante a fase ascendente do exercício, separados por eixos em diferentes arquivos do tipo *Comma Separated Values* - CSV.

A topologia geral para os MOM nesta tese teve como referência pesquisas relacionadas a movimento humano (FUJII et al., 2018; KIM; CHIEN, 2001; URGO; TARABINI; TOLIO, 2019; YAMADA et al., 2013) que utilizaram a topologia do tipo linear (FINK, 2008), sendo esta uma metodologia capaz de modelar adequadamente e apresentar boas taxas de reconhecimento pelos MOM. A Figura 18 exibe um modelo de MOM, com cinco estados (S_n), de topologia linear no qual existem apenas duas possibilidades de transições (a_n) por estado: para o estado subsequente ou para o estado atual. O último estado, nesse caso representado por S_5 , apresenta apenas uma possibilidade de transição, ou seja, apenas a possibilidade de permanecer no último estado. Isto pode representar, por exemplo, a finalização de um movimento,

ideia presente neste estudo. Os símbolos b_n são indicadores das distribuições de probabilidade de observação.


Figura 18 - Representação gráfica de um MOM de topologia linear com cinco estados.



Fonte: o autor.

Considerou-se também que os deslocamentos dos marcadores durante a realização dos exercícios descrevem trajetórias em que não há possibilidade de voltar a uma posição anterior para depois dar continuidade ao exercício ou até mesmo de saltar de uma posição intermediária para o ponto final sem percorrer os demais pontos da trajetória. Estas observações reforçam que estas trajetórias dos marcadores podem ser representadas por um MOM de topologia linear. A Figura 19 exibe o gráfico da trajetória curva descrita pelo marcador fixado à barra durante a realização de uma execução do exercício de rosca direta com barra.

Figura 19 - Gráfico da trajetória curva descrita por um marcador fixado à barra durante a realização de uma execução do exercício de rosca direta com barra.




Fonte: o autor.

Como o número de observáveis pode ser grande (tamanho da trajetória, taxa de captura x tempo, ou de termos dados supérfluos/sobrepuestos que aumentariam consumo computacional, desnecessariamente) e estamos interessados em reconhecer trajetórias em regiões bem próximas às do treinamento (trajetórias obtidas com 0% ou 25% de carga no exercício de rosca), costuma-se reduzir os dados de treinamento dos deslocamentos reais a um número funcional de estados, que os represente, por meio de um algoritmo de agrupamento (clusterização) (FUJII et al., 2018). Um dos algoritmos mais utilizados para realização deste agrupamento é o denominado *k-means* (ANDERSSON et al., 2013; ATTAL et al., 2015; COINTAULT; GOUTON, 2007; GUSMÃO et al., 2009; KOTHARI; CHAUDRY; WANG, 2009; ONG; KOSEKI; PALAFOX, 2013). O processo de formação dos *clusters* com o *k-means* é realizado por meio de um procedimento iterativo de classificação que busca a minimização de medidas de distância, neste caso, de todos os pontos do trajeto do marcador a um ou mais pontos centrais (centroides) dependendo do número de agrupamentos (KAUFMAN; ROUSSEEUW, 2009). O número de agrupamentos deve ser definido por quem aplica o método. A Figura 20 exhibe, como exemplo para fins didáticos, o resultado do agrupamento e localização de três centroides em um conjunto de pontos que constitui um movimento ascendente de rosca direta com barra com o algoritmo *k-means* implementado no *software* GNU *Octave*.


Associada à interpretação de que cada coordenada cartesiana que descreve a trajetória do marcador é entendida como uma observável do modelo, que os centroides dos clusters formados por estas observações formam os estados do modelo, e que não há outra possibilidade de transição dentro desta série temporal a não ser a posição subsequente ou finalização do movimento, esta topologia descreve muito bem a realização do exercício analisado neste estudo. A Figura 21 exhibe um exemplo deste entendimento por meio de um exercício de rosca direta com barra, em que cada centroide de agrupamento de posições bidimensionais, por intervalo de tempo, pode ser visto como um estado do modelo e que há apenas duas possibilidades de transição entre estados (ficar parado na mesma posição ou prosseguir com o movimento).

Figura 20 - Conjunto de pontos formadores da trajetória percorrida por um marcador fixado na barra durante uma execução ascendente do exercício de rosca direta com barra. A figura exibe a formação de três clusters (azul, verde e vermelho) com três centroides indicados pelos símbolos $\times$.



Fonte: o autor.

Figura 21 - Visualização da existência de estados dos MOM em um exercício de rosca direta com barra com dados de posições bidimensionais divididos em três clusters.



Fonte: o autor.

Para modelagem pelos MOM foi tomado como modelo padrão dos exercícios, para cada participante, as trajetórias dos marcadores descritas nas três primeiras execuções sem carga (somente barra). Estas primeiras execuções serviram como base de treinamento dos modelos. Visando testar a capacidade dos MOM, também foi realizada a comparação entre as trajetórias percorridas com carga intermediária e máxima, usando como treinamento dos MOM as trajetórias obtidas com carga intermediária (25% para rosca e 50% para agachamento). Nesta etapa, os parâmetros do modelo $\lambda = (A, B, \pi)$ foram calculados por meio dos símbolos observados O de forma que $P(O|\lambda)$ fosse maximizada. Este treinamento não é um problema simples e a existência de um algoritmo eficiente para resolução desse problema é condição fundamental para a aplicabilidade do MOM. Para isso se utilizou o algoritmo de *Baum-Welch*, para maximizar a probabilidade das sequências de observações (FUJII et al., 2018; RABINER, 1989a; YAMATO; OHYA; ISHII, 1992b).

Após o treinamento deu-se o processo de reconhecimento de padrões das execuções dos exercícios descritos pelas trajetórias dos marcadores selecionados. O reconhecimento destes padrões teve como base o critério de máxima verossimilhança (*maximum likelihood*). Para avaliar a verossimilhança entre um modelo treinado e uma nova sequência de observação, foi utilizado o algoritmo *Forward* (RABINER, 1989a). O algoritmo *Forward* calculou a probabilidade de que os dados de observação possam ter sido gerados pelo modelo (LIN; KULIĆ, 2011; YAMATO; OHYA; ISHII, 1992b).

Oteve-se, com os MOM, o número mínimo de estados suficientes para reconhecer as diferenças apontadas pela ANOVA nas execuções dos exercícios devido à variação da carga em termos de alteração do padrão de execução do respectivo exercício. Este teste utilizou as coordenadas cartesianas, em centímetros, com pontos de apoio (calibração) no ambiente de coleta. Também, foram encontrados valores mínimos de estados suficientes para reconhecer as diferenças apontadas pela ANOVA para MOM treinados com coordenadas cartesianas com unidades de medida apenas da imagem (*pixels*) sem o uso de pontos de apoio no ambiente de coleta. Os resultados foram comparados em gráficos de Bland Altman para verificar a possibilidade de se obter, mediante a alteração do padrão do movimento apenas na imagem, sem dados do ambiente, o reconhecimento das diferenças apontadas pela ANOVA nos testes anteriores.

Avaliação humana

Dois avaliadores, com experiência de aproximadamente 30 anos na avaliação de exercícios com cargas (rosca direta com barra e agachamento livre com barra), ambos graduados em Educação Física, observaram a realização dos exercícios executados pelos voluntários por meio de vídeos, com vistas à manutenção da referência observacional contida nos dados fornecidos aos modelos estatístico/matemáticos.

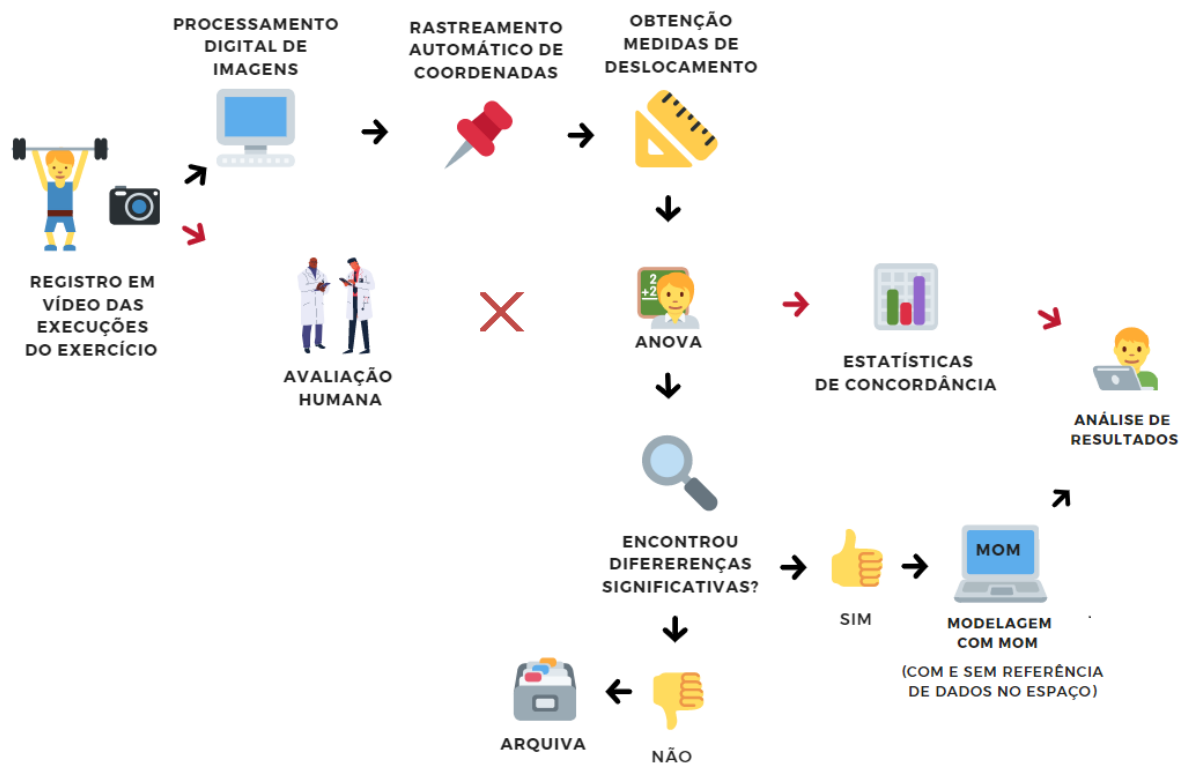
Os avaliadores analisaram visualmente as diferenças nos deslocamentos articulares pela trajetória dos marcadores com o aumento das cargas. Foram exibidos aos avaliadores os vídeos das execuções dos exercícios em monitor de 42 polegadas começando pelas execuções sem carga. As comparações fornecidas aos avaliadores para o exercício de rosca foram: barra, cotovelo e ombro a 0%-50% de carga. Para o exercício de agachamento: joelho e quadril a 0%-50% e 0%-75% de carga.

Os resultados obtidos em suas avaliações, juntamente com os obtidos pela ANOVA sobre os modelos matemáticos, foram analisados tanto por meio de percentuais de respostas em concordância, quanto pela estatística da confiabilidade inter-avaliadores, utilizando o valor do coeficiente *Kappa* de Cohen.

Resumo dos procedimentos metodológicos

Visando apresentar de forma resumida os procedimentos metodológicos utilizados neste estudo se desenvolveu o fluxograma apresentado na Figura 22. Nele se mostra de forma resumida os passos metodológicos para obtenção dos resultados dos experimentos.

Figura 22 – Fluxograma referente a metodologia do estudo.



Fonte: o autor.

7 RESULTADOS

7.1 Mensurações, ANOVAS e MOM

Os resultados obtidos apresentam-se divididos por exercício: rosca direta com barra e agachamento livre com barra. Os valores de deslocamentos para cada marcador, durante a fase ascendente do exercício Rosca direta com barra (monoarticular), para cada uma das três execuções (referência e carga à 25 e 50% do peso corporal), estão dispostos nas Tabelas 1, 2 e 3:

Tabela 1 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), sem carga (0%, condição referência) em cada uma das três execuções para cada participante. Valores mensurados em centímetros (cm).

Carga - 0%			
Participante	Barra	Cotovelo	Ombro
01	51,8	4,2	1,4
02	74,1	4,9	1,7
03	51,4	5,1	1,9
04	53,4	2,6	1,5
05	49,7	2,4	1,0
06	62,4	7,0	2,1
07	60,1	6,8	2,2
08	55,2	5,4	1,9
09	60,6	2,5	1,2
10	49,3	2,8	1,5
Média	56,8 ± 7,7	4,4 ± 1,7	1,7 ± 0,4

Fonte: o autor.

Tabela 2 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), com carga de 25% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros (cm).

Carga - 25%			
Participante	Barra	Cotovelo	Ombro
01	56,8	7,9	3,9
02	73,8	5,0	3,8
03	49,3	3,2	1,8
04	55,6	4,0	2,5
05	48,3	3,5	1,9
06	66,3	10,0	6,0
07	67,3	11,6	3,5
08	57,3	8,3	1,8
09	67,0	5,6	2,3
10	54,4	4,7	2,1
Média	59,6 ± 8,5	6,4 ± 2,9	3,0 ± 1,3

Fonte: o autor.

Tabela 3 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, cotovelo e ombro), com carga de 50% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.

Carga - 50%			
Participante	Barra	Cotovelo	Ombro
01	56,1	9,0	6,7
02	79,1	6,6	8,9
03	52,9	8,2	4,4
04	63,3	9,7	13,1
05	54,9	6,2	8,9
06	75,5	17,9	15,7
07	69,8	12,9	6,6
08	59,1	15,7	5,7
09	69,4	7,0	4,2
10	59,9	10,5	4,8
Média	64,0 ± 9,0	10,4 ± 4,0	7,9 ± 3,8

Com os valores máximos dos deslocamentos de cada marcador, representados por suas médias nas Tabelas 1, 2 e 3, se realizou a análise de variâncias ANOVA, teste post-hoc de Tukey com nível de significância $p < 0,05$, para verificar a existência de diferenças significativas no deslocamento com as três cargas. No caso da barra os valores foram obtidos com dados normalizados. Para esta normalização foi utilizado o valor do comprimento do braço direito de cada participante. Foram identificadas diferenças significativas de deslocamento da barra somente na comparação entre a execução de referência e com carga a 50% do peso corporal ($p = 0,002$). Para os deslocamentos de cotovelo foram encontradas diferenças na comparação 0%-50% ($p = 0,001$) e 25%-50% ($p = 0,043$). Para o ombro foram encontradas diferenças para as mesmas comparações 0%-50% ($p = 0,000$) e 25%-50% ($p = 0,001$). As trajetórias das articulações que apresentaram diferenças significativas de deslocamento no tratamento estatístico foram analisadas pelos MOM.

A análise dos MOM para as trajetórias destas articulações deu-se mediante orientação do modelo com os dados obtidos durante as três primeiras execuções (sem carga) de cada participante. Foi criado um modelo que foi comparado às outras execuções e encontrado um número mínimo de estados capaz de reconhecer as diferenças apontadas pelo tratamento estatístico. Como não se poderia garantir que todos os voluntários apresentariam diferenças significativas de deslocamento para estes marcadores apontados pela análise em grupo, realizou-se uma nova análise de variância ANOVA *One Way*, com teste *post-hoc* de *Tukey* com nível de significância $p < 0,05$, para cada participante. Somente destes que apresentaram diferenças significativas, criaram-se modelos com um número mínimo de estados.

O Quadro 5 exibe os valores mínimos de estados (N) necessários para reconhecimento das diferenças de padrões de posição e deslocamento, tendo como referência os valores de significância individuais (p) para cada participante (01...10), nas diferentes comparações de carga para cada um dos marcadores.

Quadro 5 – Valores mínimos para o número de estados (N) dos MOM necessários para orientar o reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas (p) por participante.

	Cargas	p/N	01	02	03	04	05	06	07	08	09	10
Cotovelo	0%-50%	p	,003	,500	,009	,005	,014	,000	,068	,002	,014	,000
		N	20	...	35	30	45	20	...	40	25	35
	25%-50%	p	,488	,543	,001	,015	,057	,000	,833	,011	,444	,001
		N	...	...	35	15	...	20	...	35	...	40
Ombro	0%-50%	p	,095	,004	,001	,010	,050	,000	,010	,001	,001	,003
		N	...	15	15	45	...	35	25	45	20	30
	25%-50%	p	,424	,019	,001	,015	,076	,002	,046	,001	,006	,007
		N	...	25	20	25	...	15	45	25	35	20
Barra	0%-50%	p	,025	,041	,798	,003	,069	,003	,016	,391	,004	,000
		N	30	45	...	60	...	35	45	...	55	40

Fonte: o autor.

Testando em todos os modelos o maior número de estados por carga encontrado, para cada articulação, chegou-se a um valor de 100% de reconhecimento das diferenças de padrões entre todos os participantes que apresentavam diferenças significativas. Mas quando se verifica, incluindo os que não apresentaram diferenças, esta taxa de acertos cai para 80% com exceção do cotovelo na relação 25%-50% do peso corporal que apresentou 60% de acertos.

Também se encontrou relação entre os deslocamentos significativos encontrados com o marcador localizado na barra e os localizados no cotovelo e ombro. Em aproximadamente 70% dos casos que houve deslocamento significativo da barra houve também deslocamento significativo do cotovelo. E, em aproximadamente 86% dos casos em que houve deslocamento significativo da barra, houve também deslocamento significativo do ombro.

Os valores de deslocamentos para cada articulação, durante a fase ascendente do exercício de agachamento livre com barra, para cada uma das três execuções (referência e carga a 50 e 75% do peso corporal), estão dispostos nas Tabelas 4, 5 e 6.

Tabela 4 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), sem carga (0%) em cada uma das três execuções para cada participante. Valores mensurados em centímetros.

Carga - 0%				
Participante	Barra	Quadril	Joelho	Tornozelo
01	56,0	26,5	8,1	0,5
02	62,5	37,5	8,2	0,2
03	65,3	40,3	11,5	0,6
04	63,6	25,6	8,1	1,3
05	63,0	28,2	7,4	0,6
06	54,1	25,5	8,0	0,3
07	79,3	39,5	10,8	0,2
08	59,0	31,5	8,0	0,3
09	72,7	38,6	11,0	0,4
10	46,7	29,9	7,2	0,5
Média	62,2 ± 9,2	32,3 ± 6,1	8,8 ± 1,6	0,5 ± 0,3

Fonte: o autor.

Tabela 5 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), com carga de 50% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.

Carga - 50%				
Participante	Barra	Quadril	Joelho	Tornozelo
01	59,6	32,8	8,8	0,3
02	56,0	35,3	7,4	0,2
03	65,6	41,7	11,5	0,7
04	66,9	31,0	9,4	0,9
05	67,1	35,2	8,8	0,5
06	58,0	31,9	9,2	0,2
07	75,5	34,2	9,5	0,3
08	63,5	36,2	9,5	0,4
09	75,7	44,4	12,0	0,4
10	49,0	30,9	8,7	0,4
Média	63,7 ± 8,4	35,4 ± 4,5	9,5 ± 1,3	0,4 ± 0,2

Fonte: o autor.

Tabela 6 – Valores médios de deslocamentos máximos obtidos para cada marcador (barra, quadril, joelho e tornozelo), com carga de 75% do peso corporal em cada uma das três execuções para cada participante. Valores mensurados em centímetros.

Carga – 75%				
Participante	Barra	Quadril	Joelho	Tornozelo
01	56,0	31,2	7,8	0,4
02	55,6	33,9	6,9	0,2
03	62,3	38,0	10,5	0,6
04	63,2	32,5	9,8	1,0
05	69,1	37,2	9,7	0,5
06	58,5	31,5	9,5	0,2
07	65,8	26,0	7,3	0,2
08	64,6	37,8	9,8	0,6
09	79,3	46,7	13,6	0,6
10	50,0	31,8	8,1	0,5
Média	62,4 ± 8,2	34,7 ± 5,6	9,3 ± 2,0	0,5 ± 0,2

Fonte: o autor.

Com os valores dos deslocamentos de cada marcador, presentes nas Tabelas 4, 5 e 6, verificou-se a existência de diferenças significativas, ou não, no deslocamento articular nas três diferentes cargas de execução. Assim como para o exercício de rosca, realizou-se a análise de variâncias com teste post-hoc de Tukey com nível de significância $p < 0,05$. Não foram encontradas diferenças significativas de deslocamento para quaisquer das articulações quando analisadas em grupo. Mesmo com o tratamento estatístico não tendo identificado diferenças significativas de deslocamento para nenhum dos marcadores/articulações para o grupo, realizou-se uma nova análise de variância para cada participante. Os marcadores que apresentaram diferenças significativas de deslocamento, para a maioria dos participantes (50% ou mais), foram analisados pelos MOM. Apenas os marcadores localizados no joelho e quadril se encaixaram neste critério. Para estes que apresentaram diferenças significativas, criaram-se modelos com um número mínimo de estados.

O Quadro 6 exibe os valores mínimos de estados (N) necessários para reconhecimento das diferenças de padrões tendo como referência os valores de

significância individuais (p) para cada participante (01...10), nas diferentes comparações de carga para cada um dos marcadores (exercício de agachamento).

Quadro 6 – Valores mínimos para o número de estados (N) dos MOM necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas (p) por participante (exercício de agachamento).

	Cargas	p/N	01	02	03	04	05	06	07	08	09	10
Joelho	0%-50%	p	,715	,061	,996	,077	,000	,028	,109	,001	,021	,009
		N	...	...	...	...	30	40	...	20	30	20
	0%-75%	p	,901	,007	,035	,023	,000	,013	,002	,000	,000	,096
		N	...	30	25	25	25	25	30	30	30	...
Quadril	0%-50%	p	,024	,434	,460	,003	,003	,000	,162	,033	,003	,295
		N	30	...	...	20	40	45	...	35	30	...
	0%-75%	p	,073	,147	,153	,001	,001	,001	,004	,009	,000	,051
		N	...	...	...	20	35	45	20	35	35	...

Fonte: o autor.

Testando em todos os modelos o maior número de estados por carga encontrado, para cada articulação, assim como para o exercício de rosca direta, também se chegou a um valor de 100% de reconhecimento das diferenças de padrões entre todos os participantes que apresentavam diferenças significativas. Quando se verifica incluindo os que não apresentaram diferenças esta taxa de acertos se mantém para o marcador localizado no joelho. A taxa também permanece para o marcador localizado no quadril na relação 0%-75% do peso corporal, mas cai para 90% na relação 0%-50%.

Para o exercício de agachamento também se encontrou relação entre os deslocamentos significativos encontrados com o marcador localizado na barra e os localizados no quadril e joelho. Dos três participantes que apresentaram diferenças significativas para barra todos apresentaram também deslocamento significativo do quadril e joelho.

7.2 MOM sem referência de coordenadas no espaço

Os valores mínimos de número de estados encontrados pela análise com MOM mostrados nos Quadros 5 e 6 foram testados com as mesmas trajetórias obtidas

somente com coordenadas de imagem (sem mensurações e/ou correções de medidas do ambiente de coleta) obtidas em “*pixels*” mantendo o mesmo referencial do teste anterior. Este teste foi realizado a fim de verificar se somente dados de posicionamento de cada articulação, mensurados na própria imagem, são suficientes para indicar alterações de padrão do movimento por MOM. Para o exercício de rosca direta os resultados se encontram no quadro 07.


Quadro 7 – Valores mínimos para o número de estados (N) dos MOM, necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas por participante. Valores obtidos somente com dados de imagem (rosca direta). Os três pontos (...) indicam que não foi encontrada diferença significativa pela ANOVA.

		Participantes									
	Cargas	01	02	03	04	05	06	07	08	09	10
Cotovelo	0%-50%	20	...	35	30	45	23	...	40	25	35
	25%-50%	...	...	35	16	...	20	...	35	...	40
Ombro	0%-50%	...	15	20	45	...	35	25	45	20	30
	25%-50%	...	25	20	25	...	15	45	25	35	21
Barra	0%-50%	30	45	...	60	...	35	45	...	55	42

Fonte: o autor.

Observa-se nos quadros 5 e 7 que ocorreram poucas alterações do número de estados com a utilização dos dois métodos (números em negrito). Apenas aproximadamente 14% dos valores sofreram alteração. Os resultados da análise de concordância entre os dois métodos são mostrados nos gráficos na Figura 23. Eles revelam que praticamente não há diferenças entre os métodos tendo em vista a pouca alteração do número de estados dos MOM.

Figura 23 - Gráficos de Bland-Altman (para exercício de rosca direta) indicando a diferença média (eixo y) e os limites de concordância de 95% ($DP \times 1,95$, linhas pontilhadas mais largas) entre as duas formas de análise pelos MOM: com mensurações no ambiente (CA) e somente com coordenadas de imagem (CI).



Fonte: o autor.

Para o exercício de agachamento os resultados se encontram no quadro 08.


Quadro 8 – Valores mínimos para o número de estados (N) dos MOM necessários para reconhecimento de diferenças entre as execuções com diferentes cargas nos casos de diferenças significativas por participante. Valores obtidos somente com dados de imagem (agachamento). Os três pontos (...) indicam que não foi encontrada diferença significativa pela ANOVA.


		Participantes									
		01	02	03	04	05	06	07	08	09	10
Joelho	Cargas										
	0%-50%	...	...	...	...	30	40	...	20	30	25
Quadril	0%-75%	...	30	25	25	25	35	30	30	30	...
	0%-50%	30	...	...	30	40	45	...	35	30	...
	0%-75%	...	...	...	25	35	45	20	35	35	...

Fonte: o autor.

Observou-se também nos quadros 6 e 8 que ocorreram poucas alterações do número de estados com a utilização dos dois métodos (números em negrito) no exercício de agachamento. Apenas 20% dos valores sofreram alteração. Os resultados da análise de concordância entre os dois métodos são mostrados nos gráficos na Figura 24. Neste caso também quase não há diferenças entre os métodos tendo em vista a pouca alteração do número de estados dos MOM.

Figura 24 - Gráficos de Bland-Altman (para exercício de agachamento) indicando a diferença média (eixo y) e os limites de concordância de 95% ($DP * 1,95$, linhas pontilhadas mais largas) entre as duas formas de análise pelos MOM: com mensurações no ambiente (CA) e somente com coordenadas de imagem (CI).






Fonte: o autor.

7.3 Avaliadores humanos

Os avaliadores humanos verificaram a existência de diferenças significativas de deslocamento das articulações de cada exercício tendo como referência as execuções sem carga (condição de referência somente com barra). Os percentuais de concordâncias, entre modelo estatístico e avaliadores, e entre ambos os avaliadores, estão presentes nos gráficos das Figuras 25, 26 e 27. Os resultados para o exercício de rosca para cada articulação são exibidos no gráfico da Figura 25.

Figura 25 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de rosca direta. Comparação 0% - 50% de carga.




Fonte: o autor.

Observa-se no gráfico da Figura 25 que o percentual de concordância entre respostas de identificação ou não de deslocamentos significativos em relação ao


referencial estabelecido (sem carga) e demais execuções (com carga) entre ANOVA e avaliadores foi maior ou igual a 70% e entre avaliadores foi maior ou igual a 80%. Os resultados percentuais de concordância para o exercício de agachamento para cada articulação são exibidos nos gráficos das Figuras 25 e 27.

Figura 26 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de agachamento. Comparação 0% - 50% de carga.



Fonte: o autor.

Figura 27 - Gráfico dos percentuais de concordância entre respostas referentes a identificações de significâncias de deslocamento para o exercício de rosca direta. Comparação 0% - 75% de carga.



Fonte: o autor.

Nos gráficos das Figuras 26 e 27 se observa menores taxas de concordância entre ANOVA e avaliadores e entre avaliadores em relação ao exercício de rosca direta. Os avaliadores conseguiram identificar a significância dos deslocamentos apontados pela ANOVA com maior frequência quando a carga era de 50% (intermediária). O quadril apresentou resultados mais concordantes tanto em relação à ANOVA quanto entre avaliadores.

A fim de verificar a concordância entre ANOVA e avaliadores e entre avaliadores também se utilizou a mensuração de concordância *kappa*. Os valores obtidos junto com o valor de significância estatística para o exercício de rosca são exibidos na Tabela 7. Foram encontrados, conforme classificação de Landis e Koch, concordâncias classificadas como substanciais para ANOVA vs. Avaliador 02 para a barra ($p = 0,003$) e para o cotovelo na comparação entre tratamento estatístico e ambos os avaliadores (Av.01 $p = 0,035$; Av.02 $p = 0,035$). Na comparação entre tratamento estatístico e Avaliador 02 para barra, obteve-se concordância moderada ($p = 0,036$), e entre avaliadores foram encontradas concordâncias quase perfeitas para barra ($p = 0,000$) e para cotovelo ($p = 0,002$).

Tabela 7 – Valores da estatística *kappa* (k). Valores referentes ao exercício de rosca.

Comparações	Barra	Cotovelo	Ombro
ANOVA vs. Av.01	0,500*	0,615*	-0,154
ANOVA vs. Av.02	0,686**	0,615*	0,211
A.01 vs. Av.02	0,843**	1,000**	0,412

* Significância a 5%.

** Significância a 1%.

Para o exercício de agachamento nas relações 0% - 50% e 0% - 75% de carga os valores encontrados para *kappa* estão nas Tabelas 8 e 9. Foi classificada na relação 0% - 50% somente a concordância entre avaliadores para o quadril como sendo substancial ($p = 0,011$). Para a relação 0% - 75% não foram encontradas concordâncias com significância estatística.

Tabela 8 – Valores da estatística *kappa* (*k*). Valores referentes ao exercício de agachamento na comparação 0% - 50% de carga.

Comparações	Joelho	Quadril
ANOVA vs. Av.01	0,200	0,091
ANOVA vs. Av.02	0,200	0,211
A.01 vs. Av.02	-0,200	0,783*

* Significância a 5%.

** Significância a 1%.

Tabela 9 – Valores da estatística *kappa* (*k*). Valores referentes ao exercício de agachamento na comparação 0% - 75% de carga. O “NC” significa que não houve cálculo pois os resultados do Avaliador 02 foram constantes.

Comparações	Joelho	Quadril
ANOVA vs. Av.01	-0,071	-0,087
ANOVA vs. Av.02	-0,250	NC
A.01 vs. Av.02	-0,071	NC

* Significância a 5%.

** Significância a 1%.

8 DISCUSSÃO

Os resultados do presente estudo mostraram que os MOM foram capazes de analisar perturbações do movimento ao reconhecer alterações da posição articular que modificaram a execução de referência de movimentos mono e multiarticulares devido a alteração de carga. Coordenadas cartesianas das trajetórias descritas pelos movimentos de articulações forneceram aos MOM dados necessários e suficientes para modelagem dos exercícios realizados. Este resultado rejeita a hipótese nula (H_0) e valida a hipótese H_1 do indicado como primeiro teste. Houve também reconhecimento das alterações de posicionamento articular pelos MOM com coordenadas de imagem sem dados de mensuração ou calibração do ambiente. Obter resultados análogos sem dados de mensuração valida a hipótese nula do segundo teste, dispensando a necessidade de se ter mensurações do ambiente.

Os resultados obtidos com os avaliadores humanos mostraram valores percentuais mais altos de concordância com o tratamento estatístico para o exercício de rosca do que para o exercício de agachamento. A menor concordância em relação ao exercício de agachamento tem relação com a maior complexidade do movimento multiarticular. Isso mostra, principalmente para o exercício de agachamento, que os MOM, treinados para esse fim, podem identificar alterações da execução de movimentos não perceptíveis a avaliadores humanos experientes. Esse resultado rejeita a hipótese nula do terceiro teste e corrobora a necessidade do uso de um modelo confiável capaz de identificar alterações dos movimentos. As validações destas hipóteses são discutidas nos tópicos a seguir.

Modelagem e reconhecimento de alterações de posição articular pelos MOM

O uso de topologia linear nos MOM (FINK, 2008; FUJII et al., 2018; URGO; TARABINI; TOLIO, 2019) foi suficiente para compreender os movimentos realizados pelos voluntários na execução dos exercícios. Relacionar as coordenadas cartesianas às observáveis dos MOM, sendo que estas coordenadas descreviam uma ordenação espaço-temporal, sem possibilidade de saltos entre estados ou recuos, fortaleceu a escolha pela topologia empregada. O algoritmo de agrupamento *k-means* realizou a segmentação das trajetórias no espaço bidimensional de forma eficiente para que se obtivesse por meio dos MOM a identificação das diferenças entre modelos nos casos apontados pela análise de variância.

O uso de um modelo bidimensional, com captura dos dados em câmera comum, forneceu dados necessários e suficientes para modelagem pelos MOM que identificaram quais execuções que apresentaram diferenças significativas baseados nos resultados da análise de variância. Foram atendidos os critérios de convergência do método estatístico (maximização de $P(O|\lambda)$ conforme Rabiner (1989), tanto para geração do modelo quanto para identificação das alterações dos movimentos. Ter encontrado o valor mínimo do número de estados (N) para reconhecimento da alteração significa, ter atingido a convergência probabilística do modelo para detecção da alteração. Um segundo aspecto relevante foi a forma de criar uma base de treinamento para o modelo. Bastou definir os movimentos corretos, capturar seus dados e utilizá-los como modelo de comparação nos MOM (RABINER; JUANG, 1986). Ressalta-se que o uso de poucas variações do movimento a ser utilizado como treinamento deixam os MOM mais rigorosos no reconhecimento de padrões dos movimentos.

Com os números mínimos de estados encontrados para o exercício de rosca (Quadro 5) para cada participante, foi elaborado um modelo capaz de reconhecer diferenças nas execuções o que pode indicar o volume máximo de carga individual, tendo em vista a alteração do padrão de execução considerado adequado. Ao se testar todos os modelos individuais com o número máximo de estados encontrado para cada marcador se obteve bom resultado de acertos chegando a atingir 100% de acertos no grupo dos que apresentaram diferenças.

A relação entre os deslocamentos significativos encontrados com o marcador localizado na barra juntamente com os localizados no cotovelo e ombro confirmam a alteração do padrão de movimento devido ao aumento da carga. Aproximadamente 70% dos casos que houve deslocamento significativo da barra houve também deslocamento significativo do cotovelo e em 86% dos casos que houve deslocamento significativo da barra houve também deslocamento significativo do ombro. Possivelmente, deve ter corrido uma readequação muscular para manutenção do equilíbrio (centro de gravidade da carga se distancia do centro de gravidade do corpo), exigindo a participação de mais músculos (BAECHLE; EARLE, 2008; DUARTE, 2000; LATASH, 1998), o que levou a alterar o posicionamento do ombro e cotovelo como identificado na maioria dos casos.

No caso do agachamento não foram encontradas diferenças significativas para o grupo como no exercício de rosca. Mesmo com uma carga proporcionalmente

superior à do exercício de rosca tem-se que a participação de diferentes músculos e articulações (SCOTT, 2000) na execução do movimento e da carga estar mais próxima do corpo (centro de gravidade da carga próximo do centro de gravidade do corpo), possa ter atenuado a necessidade de manutenção do equilíbrio tornado os deslocamentos articulares mais restritos. Mesmo assim, foram encontrados deslocamentos significativos individuais para duas articulações: joelho e quadril. Para estes casos houve modelagem pelos MOM e também foram encontrados números mínimos de estados para reconhecimento das diferenças entre padrões de movimento (Quadro 6).

De forma análoga ao exercício de rosca direta, também se chegou a um valor de 100% de reconhecimento das diferenças de padrões entre todos os participantes que apresentavam diferenças significativas, testando em todos os modelos o maior número de estados encontrado para cada articulação. Também se detectou relação entre os deslocamentos significativos encontrados com o marcador localizado na barra e os localizados no quadril e joelho. Dos três participantes que apresentaram diferenças significativas para barra (participantes 6, 7 e 8) todos apresentaram também deslocamento significativo do quadril e joelho.

MOM sem referência de coordenadas no espaço

Como na análise dos exercícios observou-se que os MOM apresentaram um bom desempenho sobre a capacidade de identificar diferenças de deslocamentos, que alteraram o padrão de movimento, surgiu a necessidade de verificar se o movimento em si, sem dados métricos do ambiente, poderia ser analisado pelos MOM e obter resultados análogos. Desta forma os mesmos vídeos foram utilizados para fornecer aos MOM coordenadas de imagem (em *pixels*), sem dados de mensuração ou calibração do ambiente, de cada uma das articulações envolvidas. A validação do uso de coordenadas de imagem deu-se mediante a comparação do número mínimo de estados obtidos com os encontrados para os experimentos realizados com coordenadas em centímetros e correções métricas do ambiente.

Para o exercício de rosca ocorreram poucas alterações do número de estados com a utilização dos dois métodos (aproximadamente 14% de alterações). Também se observou que ocorreram poucas alterações do número de estados com a utilização dos dois métodos no exercício de agachamento. Somente 20% dos valores sofreram alteração. Os resultados da análise de concordância entre os dois métodos para

ambos os exercícios, mostrados pelos gráficos de Bland Altman revelaram que praticamente não houve diferenças entre os métodos. Percebe-se em todos os gráficos que a média da diferença entre os dois métodos está próxima do zero e que a maioria dos valores está dentro do intervalo de confiança definido pelo método.

A concordância apresentada foi satisfatória entre as duas formas de obtenção de dados. Isso mostra que a análise da trajetória do movimento, sem qualquer dado do ambiente, é suficiente para detectar alterações do padrão durante a realização do exercício. Este é um importante resultado, tendo em vista que possibilita a análise pelos MOM de vídeos que tenham sido gravados sem que fossem tomados dados do ambiente de execução e até mesmo dispensa mensurações sobre o praticante do exercício.

Análise humana

A fim de se compararem os resultados apontados pela ANOVA com observações humanas houve a participação dos profissionais experientes em avaliar a execução de exercícios de rosca e agachamento. Os resultados dos avaliadores, junto com as identificações pela ANOVA foram comparados e seus percentuais de concordância exibidos nos gráficos das Figuras 25, 26 e 27.

Para o exercício de rosca houve um grande percentual de concordância entre respostas, tanto dos avaliadores com a ANOVA quanto entre avaliadores. O gráfico da Figura 25 exibe estes percentuais de concordância. Nele se percebe boa concordância entre avaliadores, ou seja, há consistência entre a percepção de erro na avaliação humana. O percentual de consonância das respostas de 70% a 90% entre o modelo matemático e a percepção de discrepância do movimento pela avaliação humana, sugere o alinhamento entre modelo estatístico/matemático e observação humana. As maiores inconsistências entre respostas foram para o movimento de ponto com menor movimentação, o ombro. Este resultado obtido para o ombro pode ser atribuído à falta de preocupação com uma articulação de menor contribuição para o desempenho (não é foco de atenção) e/ou o movimento dele ter sido pouco perceptível ao olho humano.

Para o exercício de agachamento os percentuais de concordância entre ANOVA e avaliadores foram inferiores. Os gráficos das Figuras 26 e 27 exibem estes percentuais. Para as execuções realizadas com carga de 50% do peso corporal os avaliadores obtiveram um percentual de concordância de 60% a 70% com o modelo

estatístico, mas houve discordância entre os profissionais quanto aos deslocamentos do joelho (40%). Já para o quadril ambos os avaliadores estavam alinhados em relação às suas observações (90%). Com a alteração de carga para 75% do peso corporal houve menor consonância de respostas entre avaliadores e ANOVA e entre avaliadores. As respostas concordantes entre avaliadores e modelo estatístico não ultrapassaram 60% e entre avaliadores novamente uma baixa taxa de concordância para observações do joelho (40%).

Cabe lembrar que o exercício de agachamento não apresentou diferenças significativas para ANOVA realizada com dados do grupo, assim como foi identificado para o exercício de rosca. Mesmo com a normalização de dados não se identificaram diferenças significativas para nenhuma das articulações no grupo. Não identificar por meio de cálculos matemáticos com análise estatística no grupo sugere que em média geral os deslocamentos foram inferiores aos apresentados pelo exercício de rosca, e desta forma podem não ter sido percebidos pelos avaliadores humanos. Além disso, por este ser um exercício multiarticular com a participação de maior número de músculos (SCOTT, 2000), a carga utilizada – deslocada mais próxima à linha vertical que passa pelo centro de gravidade corporal – pode não ter sido suficiente para provocar maiores desestabilizações posturais nos participantes.

Por outro lado, a identificação de diferenças significativas de deslocamento apontadas pela ANOVA garante a existência de movimentos fora do padrão estabelecido e que nem sempre foram identificados pelos avaliadores humanos. Os MOM conseguiram modelar perfeitamente os casos apontados pelo tratamento estatístico obtendo alta taxa de reconhecimento no grupo de participantes com diferenças significativas. Neste fato percebe-se que os MOM podem identificar, de maneira mais precisa e rápida, alterações de padrões não perceptíveis aos humanos, as quais podem ter ocorrido por falta de atenção ou até mesmo por não apresentarem tanta relevância ao avaliador físico.

Ainda foi realizada a análise de concordância para dados dicotômicos *kappa* interavaliadores para verificar a concordância entre ANOVA e avaliadores humanos e entre avaliadores humanos. Para o exercício de rosca os marcadores localizados na barra e cotovelo apresentaram resultados (Tabela 07) conforme classificação de Landis e Koch (1977) variando de moderada a substancial atingindo bom valor de significância ($p < 0,01$) na comparação entre ANOVA e avaliadores. Na análise entre os avaliadores humanos a concordância foi quase perfeita, mostrando que os

avaliadores estavam alinhados com o método de avaliação proposto. Para o ombro, mesmo que os percentuais de concordância entre respostas mostrados anteriormente tenham sido consideráveis, não se encontrou significância para *kappa*.

Para o exercício de agachamento, os valores percentuais de concordância já indicavam baixa concordância para a estatística *kappa* exibida nas Tabelas 8 e 9. A única significância estatística encontrada foi interavaliadores humanos para o quadril na comparação 0%-50% do peso corporal que apresentou significância substancial. Comparando os resultados percentuais de consonância entre respostas do modelo com avaliadores e interavaliadores observou-se que a estatística *kappa* não representou muito bem a concordância entre eles. Isso se percebe em comparações que atingiram 60% de concordância (joelho a 50% do peso corporal) entre ANOVA e avaliadores humanos, mas que na estatística *kappa* não apresentou significância ($k=0,200$ e $p = 0,292$ para avaliador 01 e $k=0,200$ e $p = 0,527$ para avaliador 02). Além disso, um resultado percentual de 90% de consonância (quadril, interavaliadores humanos a 50% de carga) só atingiu a segunda faixa de classificação da estatística *kappa*.

9 CONSIDERAÇÕES FINAIS

Com base nos resultados do presente estudo, pode-se concluir que o uso de Modelos Ocultos de Markov apresenta viabilidade na identificação de alterações de padrão de movimentos humanos submetidos a exercícios mono e multiarticulares, com sobrecarga, pela análise de posicionamento articular. Dados de trajetórias bidimensionais foram suficientes para que os MOM modelassem o movimento e identificassem perturbações nos movimentos realizados. A partir desses resultados, é possível admitir que MOM sejam utilizados para análise do perfil de execução dos movimentos descritos neste estudo, permitindo inferir sobre os ajustes/desajustes motores face a um referencial padronizado.

O experimento realizado somente com coordenadas de imagens forneceu um importante resultado para aplicação dos MOM. Foi encontrada uma alta concordância entre os métodos (coordenadas com referência no espaço vs. sem referência). Isso garante que se pode obter a identificação de perturbações, ou reajustes, de movimento, em vídeo, sem a necessidade de mensurações sobre participante ou ambiente de coleta. Além disso, este método abre a possibilidade de avaliarem-se movimentos registrados em outros vídeos, obtidos no passado, sem qualquer referência métrica dos dados.

A participação de avaliadores humanos mostrou o alinhamento do método com a interpretação profissional da execução adequada. No exercício de rosca, tanto a análise de variâncias quanto os avaliadores identificaram deslocamentos discrepantes com o aumento da carga. Isso mostra que possivelmente a variabilidade natural do exercício não foi confundida com a alteração do padrão do movimento, mas interpretadas como ajustes motores perceptíveis e diferentes do referencial. No caso do exercício de agachamento, nem todas as identificações pelo modelo estatístico foram percebidas pelos avaliadores humanos, mas os MOM foram capazes de identificar alterações de movimento não percebidas por análise visual dos profissionais da área.

10 REFERÊNCIAS

AABERG, Everett. *Musculação Biomecânica e Treinamento*. Barueri, p. 216, 2001.

ABDELKADER, Mohamed F. et al. Silhouette-based gesture and action recognition via modeling trajectories on Riemannian shape manifolds. **Computer Vision and Image Understanding**, v. 115, n. 3, p. 439–455, 2011. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1077314210002377>

AHMAD, Mohiuddin.; LEE, Seong-whan. HMM-based Human Action Recognition Using Multiview Image Sequences. **18th International Conference On Pattern Recognition (ICPR'06)**, Hong Kong, p.263-266, 2006. IEEE. <http://dx.doi.org/10.1109/icpr.2006.630>.

AMADIO, A. C.; DUARTE, M. **Fundamentos biomecânicos para análise do movimento**. São Paulo: EEFUSP, 1996.

AMADIO, Alberto Carlos; SERRÃO, Júlio Cerca. Contextualização da biomecânica para a investigação do movimento: fundamentos, métodos e aplicações para análise da técnica esportiva. **Revista Brasileira de Educação Física e Esporte**, 61-85, 2007. <https://doi.org/10.1590/S1807-55092007000500006>

ANDERSSON, Maria et al. Recognition of Anomalous Motion Patterns in Urban Surveillance. **IEEE Journal of Selected Topics in Signal Processing**, v. 7, n. 1, p. 102–110, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6403493/>>

AOKI, Takashi; VENTURE, Gentiane; KULIC, Dana. Segmentation of Human Body Movement Using Inertial Measurement Unit. In: 2013 IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS 2013, **Anais...** : IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6721958/>>

ARSLAN, Muhammad; CRUZ, Christophe; GINHAC, Dominique. Semantic trajectory insights for worker safety in dynamic environments. **Automation in Construction**, v. 106, p. 102854, 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0926580518311890>>

ATTAL, Ferhat et al. **Physical human activity recognition using wearable sensors****Sensors (Switzerland)**MDPI AG, 2015.

AUGUSTSSON, J.et al.Effect of pre-exhaustion exercise on lower-extremity muscle activation during a leg press exercise. **J StrengthCond Res.**, v. 17, n. 2, p. 411-416, 2003.

BAECHLE, T. R.; EARLE, R. W. **Essentials of Strength Training and Conditioning**. 3. ed: Human Kinetics, 2008.

BARTLETT, Roger. **Introduction to Sports Biomechanics**. 2. ed. Abingdon: Routledge, 2007. Disponível em: <https://www.taylorfrancis.com/books/9780203462027>

BAUM, L. E.; PETRIE, T. Statistical inference for probabilistic functions of finite state Markov chains, **Ann. Math. Stat.**, v. 37, p. 1554-1563, 1966.

BÉZIER, M.M.; PIET, S. **A coordenação motora: aspecto mecânico da organização psicomotora do homem**. São Paulo: Summus, 1992

BOGACZ, Bartosz; KLINGMANN, Maximilian; MARA, Hubert. Automating Transliteration of Cuneiform from Parallel Lines with Sparse Data. In: 2017 14TH IAPR INTERNATIONAL CONFERENCE ON DOCUMENT ANALYSIS AND RECOGNITION (ICDAR) 2017, **Anais...** : IEEE, 2017. Disponível em: <<http://ieeexplore.ieee.org/document/8270037/>>

BORGES, C.K. Coordenação e controle motor: Um estudo sobre a posição de coordenação do método de Piet e Bézier. 2009. 81 f. Dissertação (Mestrado em Ciências do Movimento Humano) - Universidade Federal do Rio Grande do Sul Escola de Educação Física Pós-graduação em Ciências do Movimento Humano, Porto Alegre. 2009.

BORUAH, Dhruvajyoti; SARMA, Kandarpa Kumar; TALUKDAR, Anjan Kumar. Different face regions detection based facial expression recognition. In: 2015 2ND INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING AND INTEGRATED NETWORKS (SPIN) 2015, **Anais...** : IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7095280/>>

BUNKE, H.; ROTH, M.; SCHUKAT-TALAMAZZINI, E. G. Off-line cursive handwriting recognition using hidden markov models. **Pattern Recognition**, v. 28, n. 9, p. 1399–1413, 1995. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/003132039500013P>>

CARRASCO, Miguel; CLADY, Xavier. Exploiting eye–hand coordination to detect grasping movements. **Image and Vision Computing**, v. 30, n. 11, p. 860–874, 2012. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0262885612001035>>

CASTRO, Armando Antonio Monteiro; PRADO, Pedro Paulo Leite. Algoritmos para reconhecimento de padrões. **Rev. Ciênc. Exatas**, v. 5–8, p. 129–145, 2002.

CHAMBERS, G. S. et al. Hierarchical recognition of intentional human gestures for sports video annotation. In: OBJECT RECOGNITION SUPPORTED BY USER INTERACTION FOR SERVICE ROBOTS 2002, **Anais...** : IEEE Comput. Soc, 2002. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1048493

CHANDLER, T. J.; BROW, L. E. **Treinamento de força para desempenho humano**. 1. ed. Porto Alegre: Artmed, 2009.

CHAO, E.Y.S. Biomechanics of the human gait. In: SCHMID-SCHÖNBEIN, G.; WOO, S.L.; ZWEIFACH, Y. (Eds.). **Frontiers in biomechanics**. New York: Springer Verlag, 1986. p.225-42.

CHEN, Hsuan-Sheng; TSAI, Wen-Jiin. A framework for video event classification by modeling temporal context of multimodal features using HMM. **Journal of Visual**

Communication and Image Representation, v. 25, n. 2, p. 285–295, 2014.
Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1047320313002150>>

CHERIET, Mohamed et al. **Character Recognition Systems**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2007.

COINTAULT, F.; GOUTON, P.. Texture or Color Analysis in Agronomic Images for Wheat Ear Counting. **2007 Third International IEEE Conference On Signal-image Technologies And Internet-based System**, p.696-701, dez. 2007. IEEE.
<http://dx.doi.org/10.1109/sitis.2007.80>.

CORREA, Mauricio et al. Real-Time Hand Gesture Recognition for Human Robot Interaction. **Robocup 2009: Robot Soccer World Cup XIII**, p.46-57, 2010. Springer Berlin Heidelberg. http://dx.doi.org/10.1007/978-3-642-11876-0_5.

DARAMOLA, S. Adebayo et al. Automatic Vehicle Identification System Using License Plate. **International Journal of Engineering Science and Technology**, v. 3, n. 2, p. 1712–1719, 2011.

DELONE, B. D. **The St. Petersburg School of Number Theory**. American Mathematical Society, 2005.

DIAS, Raquel de Souza Ferreira. **Normalização de locutor em sistema de reconhecimento de fala**. 2000. UNIVERSIDADE ESTADUAL DE CAMPINAS – UNICAMP FACULDADE, Campinas, 2000. Disponível em:
<<http://repositorio.unicamp.br/jspui/handle/REPOSIP/261949>>

DUARTE, Marcos. **Análise establográfica da postura ereta quasi-estática**. 2000. Universidade de São Paulo, [s. l.], 2000.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed. New York : Wiley, 2001.

DYMARSKI, Przemyslaw. **HIDDEN MARKOV MODELS , Edited by Przemyslaw Dymarski**. Rijeka: Kluwer Academic Publishers, 2011. Disponível em:
<<http://www.intechopen.com/books/show/title/hidden-markov-models-theory-and-applications>>

EL-YACOUBI, A. et al. An HMM-based approach for off-line unconstrained handwritten word modeling and recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 21, n. 8, p. 752–760, 1999. a. Disponível em: <<http://ieeexplore.ieee.org/document/784288/>>

EL-YACOUBI, A. et al. Off-Line Handwritten Word Recognition using Hidden Markov Models. **Knowledge-based intelligent techniques in character recognition**, p. 193–229, 1999. b. Disponível em:
<<http://www.computer.org/portal/web/csdl/doi/10.1109/34.291449%5Cnhttp://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.10.3615&rep=rep1&type=pdf>>

EL-YACOUBI, A. et al. Off-line signature verification using HMMs and cross-validation. In: NEURAL NETWORKS FOR SIGNAL PROCESSING X. PROCEEDINGS OF THE 2000 IEEE SIGNAL PROCESSING SOCIETY WORKSHOP (CAT. NO.00TH8501) 2000, **Anais...** : IEEE, 2000. Disponível em: <<http://ieeexplore.ieee.org/document/890166/>>

ESPINDOLA, Luciana Da Silveira. Um Estudo sobre Modelos Ocultos de Markov HMM - Hidden Markov Model. Porto Alegre, p. 33, 2009. Disponível em: <http://www.inf.pucrs.br/peg/pub/tr/T11_Luciana.pdf>

FINK, Gernot A. **Markov Models for Pattern Recognition**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. Disponível em: <<http://link.springer.com/10.1007/978-3-540-71770-6>>

Fleck, S.J. **Fundamentos do treinamento de força muscular**. ed. W.J. Kramer. Porto Alegre: ARTMED.1999.

FREITAS, Cinthia Obladen De Almendra et al. Brazilian bank check handwritten legal amount recognition. **Brazilian Symposium of Computer Graphic and Image Processing**, Gramado, v. 2000- Janua, p. 97–104, 2000.

FUJII, Kenko et al. Gaze gesture based human robot interaction for laparoscopic surgery. **Medical Image Analysis**, v. 44, p. 196–214, 2018. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S1361841517301809>>

GAO, Wen Chao; LI, Guo Liang; TA, Na. **Survey of Map Matching Algorithms**Ruan Jian Xue Bao/**Journal of Software**. Chinese Academy of Sciences, 2018.

GENTIL, P. Effects of exercise order on upper-body muscle activation and exercise performance.**J Strength Cond Res.**, v. 21, n. 4, p. 1082-1086, 2007.

GEORGE, G.S. **Biomechanics of women's gymnastics**. Englewood Cliffs: Prentice Hall, 1980.

GHAHRAMANI, Zoubin. **Zoubin Ghahramani Software**. 2019. Disponível em: <<http://mlg.eng.cam.ac.uk/zoubin/software.html>>. Acesso em: 11 dez. 2019.

GHARASUIE, M. M.; SEYEDARABI, H. Real-time dynamic hand gesture recognition using hidden Markov models. In: IRANIAN CONFERENCE ON MACHINE VISION AND IMAGE PROCESSING, MVIP 2013, **Anais...** : IEEE Computer Society, 2013.

GHOJOGH, Benyamin; MOHAMMADZADE, Hoda; MOKARI, Mozghan. Fisherposes for Human Action Recognition Using Kinect Sensor Data. **IEEE Sensors Journal**, v. 18, n. 4, p. 1612–1627, 2018.

GHOTKAR, Archana; VIDAP, Pujashree; DEO, Kshitish. Dynamic Hand Gesture Recognition using Hidden Markov Model by Microsoft Kinect Sensor. **International Journal of Computer Applications**, v. 150, p. 5–9, 2016.

GNU OCTAVE. **GNU Octave**. 2019. Disponível em:
<<https://www.gnu.org/software/octave/>>. Acesso em: 5 maio. 2018.

GONZÁLEZ, Miriam Ruiz. **Advanced techniques for human activity classification**. 2012. Universidad de Oviedo, 2012. Disponível em:
<<http://digibuo.uniovi.es/dspace/handle/10651/5399>>. Acesso em: 12 maio. 2018.

GU, Ye et al. Human gesture recognition through a Kinect sensor. In: 2012 IEEE INTERNATIONAL CONFERENCE ON ROBOTICS AND BIOMIMETICS (ROBIO) 2012, Guangzhou, China. **Anais...** Guangzhou, China: IEEE, 2012. Disponível em:
<<http://ieeexplore.ieee.org/document/6491161/>>

GUSMAO, G.; MACHADO, S.c.s.; RODRIGUES, M.a.b.. A new algorithm for segmenting and counting aedes aegypti eggs in ovitraps. **2009 Annual International Conference Of The Ieee Engineering In Medicine And Biology Society**, Minneapolis, Minnesota, p.6714-6717, set. 2009. IEEE.
<http://dx.doi.org/10.1109/iembs.2009.5333759>.

HAGLER, Stuart. **Patterns of selection of human movements I: Movement utility, metabolic energy, and normal walking gaits**. arXiv:1608.03583 [q-bio.QM], 2016.

HAJI-ABOLHASSANI, Amin; CLARK, James J. An inverse Yarbus process: Predicting observers' task from eye movement patterns. **Vision Research**, v. 103, p. 127–142, 2014. Disponível em:
<<https://linkinghub.elsevier.com/retrieve/pii/S0042698914002004>>

HALL, Susan J. **Biomecânica básica**. 5. ed. Barueri: Editora Manole, 2009.

HERTA, Christian. **ChristianHerta**. 2019. Disponível em:
<<http://www.christianherta.de/kmeans.php>>. Acesso em: 11 dez. 2019.

HILLIER, Frederick S.; LIEBERMAN, Gerald J. **Introdução à pesquisa operacional**. São Paulo: McGraw-Hill, 2006.

HOOGENBOOM, Barb; VOIGHT, Michael L.; COOK, Gray. Functional Movement Assessment. **Physical Rehabilitation Of The Injured Athlete**, p.482-502, 2012. Elsevier. <http://dx.doi.org/10.1016/b978-1-4377-2411-0.00022-8>.

HOQUE, S. M. Arifu.; HAQ, Md Sadun; HASANUZZAMAN, Md. Computer Vision Based Gesture Recognition for Desktop Object Manipulation. In: 2018 INTERNATIONAL CONFERENCE ON INNOVATION IN ENGINEERING AND TECHNOLOGY, ICIET 2018 2019, **Anais...** : Institute of Electrical and Electronics Engineers Inc., 2019.

IBM. **Análise de Dados com Software SPSS - IBM Brasil**. 2019. Disponível em:
<<https://www.ibm.com/br-pt/analytics/spss-statistics-software>>. Acesso em: 13 dez. 2019.

JACOBS, Ron; VAN INGEN SCHENAU, Gerrit Jan. Intermuscular coordination in a sprint push-off. **Journal of Biomechanics**, v. 25, n. 9, p. 953–965, 1992. Disponível

em: <<https://linkinghub.elsevier.com/retrieve/pii/002192909290031U>>

JUANG, B. H.; RABINER, L. R. Hidden Markov Models for Speech Recognition. **Technometrics**, v. 33, n. 3, p. 251–272, 2012. Disponível em: <<http://www.tandfonline.com/doi/abs/10.1080/00401706.1991.10484833#.VgnPLINViko>>

JUSTINO, Edson J. R.; BORTOLOZZI, Flávio; SABOURIN, Robert. Off-line signature verification using HMM for Random, simple and skilled forgeries. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON DOCUMENT ANALYSIS AND RECOGNITION, ICDAR 2001, **Anais...** : IEEE Computer Society, 2001.

JUSTINO, Edson José Rodrigues. **O Grafismo e os Modelos Escondidos de Markov na Verificação Automática de Assinaturas**. 2001. PUCPR, Curitiba, 2001.

KAFADAR, Karen et al. Encyclopedia of Statistical Sciences. **Journal of the American Statistical Association**, 2006.

KARG, Michelle et al. Human Movement Analysis: Extension of the F-Statistic to Time Series Using HMM. In: 2013 IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS 2013, **Anais...** : IEEE, 2013. Disponível em: <<http://ieeexplore.ieee.org/document/6722413/>>

KATANFOROUSH, Ali; REZVANI, Zahra. Recognition of Farsi handwriting strokes using profile HMM. In: 2015 2ND INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION AND IMAGE ANALYSIS (IPRIA) 2015, **Anais...** : IEEE, 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7161646/>>

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding Groups in Data: An Introduction to Cluster Analysis**. New Jersey: Wiley, 2009.

KIM, In Cheol; CHIEN, Sung Il. Analysis of 3D hand trajectory gestures using stroke-based composite hidden Markov models. **Applied Intelligence**, 2001.

KINOVEA. **Kinovea**. 2019. Disponível em: <<https://www.kinovea.org/>>. Acesso em: 20 maio. 2019.

KNUDSON, Duane. **Fundamentals of Biomechanics**. 2ª ed. Chico: Springer 2007.

KNUDSON, Duane V; MORRISON, Graig S. **Análise qualitativa do movimento humano**. 1ª ed. São Paulo: Manole, 2001.

KOERICH, A. L. Handwritten Word Recognition Using Markov Models. **IEEE Latin America Transactions**, v. 2, n. 2, p. 132–141, 2004. Disponível em: <<http://ieeexplore.ieee.org/document/1468632/>>

KOERICH, A. L.; SABOURIN, R.; SUEN, C. Y. Large vocabulary off-line handwriting recognition: A survey. **Pattern Analysis and Applications**, v. 6, n. 2, p. 97–121, 2003.

KOTHARI, Sonal; CHAUDRY, Qaiser; WANG, May D.. Automated cell counting and cluster segmentation using concavity detection and ellipse fitting techniques. **2009 IEEE International Symposium On Biomedical Imaging: From Nano to Macro**, Boston, Massachusetts, p.795-798, jun. 2009. IEEE.
<http://dx.doi.org/10.1109/isbi.2009.5193169>.

KRAEMER, W.J.; HAKKINEN, K. **Treinamento de força para o esporte**. Artmed Editora, São Paulo, 2004

KRAEMER, William J.; RATAMESS, Nicholas A.. Fundamentals of Resistance Training: Progression and Exercise Prescription. **Medicine and Science In Sports and Exercise**. v. 36, n. 4, p.674-688, abr. 2004.

KWON, Junghyun; PARK, F. C. Natural Movement Generation Using Hidden Markov Models and Principal Components. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, v. 38, n. 5, p. 1184–1194, 2008. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4579749>

KWON, Junghyun; PARK, Frank C. Using hidden Markov models to generate natural humanoid movement. **IEEE International Conference on Intelligent Robots and Systems**, Beijing, China, p. 1990–1995, 2006.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159–74, 1977. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/843571>

LATASH, M. L. **Neurophysiological basis of movement**. Human Kinetics, 1998.

LEE, Hwajeong et al. Real-time automatic vehicle management system using vehicle tracking and car plate number identification. In: PROCEEDINGS - IEEE INTERNATIONAL CONFERENCE ON MULTIMEDIA AND EXPO 2003, **Anais...** : IEEE Computer Society, 2003.

LI, Guoyou et al. Improvement and implementation of dynamic gesture recognition algorithm based on Kinect. **Gaojishu Tongxin/Chinese High Technology Letters**, v. 29, n. 9, p. 841–851, 2019.

LIN, Jonathan Feng-Shun; KULIĆ, Dana. Automatic Human Motion Segmentation and Identification using Feature Guided HMM for Physical Rehabilitation Exercises. In: Proceedings of the IEEE International Conference on Intelligent Robots and Systems, Workshop on Robotics for Neurology and Rehabilitation 2011, **Anais...** : IEEE Computer Society, 2011.

LIU, Zhi-Qiang; CAI, Jinhai; BUSE, Richard. **Handwriting Recognition**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. v. 133 Disponível em: <http://link.springer.com/10.1007/97>

MAGILL, Richard A. **Aprendizagem e controle motor: conceitos e aplicações**. 8. ed. São Paulo: Phorte, 2011.

MANNINI, Andrea; SABATINI, Angelo Maria. Accelerometry-Based Classification of Human Activities Using Markov Modeling. **Computational Intelligence and Neuroscience**, v. 2011, p. 1–10, 2011.

MARQUES, Inara. Padrão fundamental de movimento: uma análise universal ou contextual?. 1995. [172]f. Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Educação Física, Campinas, SP. Disponível em: <<http://www.repositorio.unicamp.br/handle/REPOSIP/275300>>.

MATHWORKS. **Hidden Markov Models (HMM) - MATLAB & Simulink**. 2019. Disponível em: <<https://www.mathworks.com/help/stats/hidden-markov-models-hmm.html>>. Acesso em: 10 dez. 2019.

MATLANI, Princy; SHRIVASTAVA, Manish. Hybrid deep VGG-net convolutional classifier for video smoke detection. **CMES - Computer Modeling in Engineering and Sciences**, v. 119, n. 3, p. 427–458, 2019.

MCKEAN, Mark R.; DUNN, Peter K.; BURKETT, Brendan J. Quantifying the movement and the influence of load in the back squat exercise. **Journal of Strength and Conditioning Research**, 2010.

MENDES, Nuno et al. Human Behavior and Hand Gesture Classification for Smart Human-robot Interaction. **Procedia Manufacturing**, v. 11, p. 91–98, 2017.

MENDES, Rui et al. Observação como instrumento no processo de avaliação em Educação Física. **Exedra**, n. 6, p. 57–70, 2012.

MOHER, David et al. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **PLoS medicine**, v. 6, n. 7, 2009. Disponível em: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC2707599>

MOKARI, Mozghan; MOHAMMADZADE, Hoda; GHOJOGH, Benyamin. Recognizing Involuntary Actions from 3D Skeleton Data Using Body States. **Scientia Iranica**, 2018.

MONI, M. A.; ALI, A. B. M. Shawkat. HMM based hand gesture recognition: A review on techniques and approaches. **2009 2nd IEEE International Conference On Computer Science And Information Technology**, Beijing, China, p.433-437, 2009. IEEE. <http://dx.doi.org/10.1109/iccsit.2009.5234536>.

MOTA, Yomara Lima; MOCHIZUKI, Luis; CARVALHO, Gustavo de Azevedo. Influência da resolução e da distância da câmera nas medidas feitas pelo software de avaliação postural (sapo). **Revista Brasileira de Medicina do Esporte**, 2011.

NAM, Yanghee; WOHN, KwangYun. Recognition of space-time hand-gestures using hidden Markov model. In: 2019, **Anais... : Association for Computing Machinery (ACM)**, 2019.

NEWELL, K. M. Coordination, Control and Skill. **Advances in Psychology**, 1985.

NSCA. **Manual de Técnicas de Exercício para Treinamento de Força**. 2. ed. Porto Alegre: Artmed, 2010.

OLIVEIRA, L. E. S.; MORITA, M. E. **Introdução aos Modelos Escondidos de Markov (HMM)**. Curitiba.

ONG, Wee Hong; KOSEKI, Takafumi; PALAFOX, Leon. An unsupervised approach for human activity detection and recognition. **International Journal of Simulation: Systems, Science and Technology**, v. 14, n. 5, p. 42–49, 2013.

OSMAN, Asmaa A. E. et al. Trajectory learning using posterior hidden Markov model state distribution Posterior Hidden Markov Model State Distribution. **Egyptian Informatics Journal**, 2017.

OZDEMIR, Erdem; TOPCU, Ahmet E.; OZDEMIR, Mehmet Kemal. A hybrid HMM model for travel path inference with sparse GPS samples. **Transportation**, v. 45, n. 1, p. 233–246, 2018.

PAO, Hsing Kuo et al. Trajectory analysis for user verification and recognition. **Knowledge-Based Systems**, 2012.

PAVLOVIC, Vladimir I.; SHARMA, Rajeev; HUANG, Thomas S. Visual interpretation of hand gestures for human-computer interaction: A review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 1997.

PENSADOR. **Pensador: frases – Nikola Tesla**. 2020. Disponível em: <<https://www.pensador.com/frase/Mjc2ODgzNw/>>. Acesso em: 10 jun. 2020.

PLOETZ, Thomas; FINK, Gernot A. **Markov Models for Handwriting Recognition**. London: Springer London, 2011. Disponível em: <<http://link.springer.com/10.1007/978-1-4471-2188-6>>

RABINER, L.; JUANG, B. H. **Fundamentals of speech recognition**. New Jersey: Prentice-Hall, 1993.

RABINER, L. R. A tutorial on hidden Markov models and selected applications in speech recognition. **Proceedings of the IEEE**, v. 77, n. 2, p. 257–286, 1989.

RABINER, L. R.; JUANG, B. H. An Introduction to Hidden Markov Models. **IEEE ASSB Magazine**, v. 3, n. January, p. 4–16, 1986.

RAHEJA, J. L. et al. Robust gesture recognition using Kinect: A comparison between DTW and HMM. **Optik**, 2015.

SAINI, Rajkumar et al. Don't just sign use brain too: A novel multimodal approach for user identification and verification. **Information Sciences**, 2018.

SALLES, B. F. Comparação do método pré-exaustão e da ordem inversa em exercícios para membros inferiores. **Rev EducFis.**, v. 19, n. 1, p. 85-92, 2008

SAMANTA, Oendrilá et al. An HMM framework based on spherical-linear features for online cursive handwriting recognition. **Information Sciences**, v. 441, p. 133–151, 2018. Disponível em: <<https://doi.org/10.1016/j.ins.2018.02.004>>

SAMARIA, F. S.; HARTE, A. C. Parameterisation of a stochastic model for human face identification. **Proceedings Of 1994 IEEE Workshop On Applications Of Computer Vision**, p.138-142, 1994. IEEE Comput. Soc. Press. <http://dx.doi.org/10.1109/acv.1994.341300>.

Samsung. 2019. Disponível em: <<https://www.samsung.com/br/smartphones/galaxy-s9/camera/>>. Acesso em: 1 jan. 2020.

SANTOS, André et al. Probabilidades Intervalares em Modelos Ocultos de Markov. **TEMA - Tendências em Matemática Aplicada e Computacional**, v. 7, 2006.

SANTOS, Murilo. **Combinando características complementares em modelos escondidos de Markov: uma otimização para o reconhecimento de caracteres manuscritos**. 2009. Pontifícia Universidade Católica do Paraná, 2009.

SCHMIDT, Richard A.; WRISBERG, Craig A. **Aprendizagem e performance motora**. 4. ed. Porto Alegre: Artmed, 2010.

SCOTT, Stephen H. Role of motor cortex in coordinating multi-joint movements: Is it time for a new paradigm? **Canadian Journal of Physiology and Pharmacology**, v. 78, n. 11, p. 923–933, 2000. Disponível em: <<http://www.nrcresearchpress.com/doi/10.1139/y00-064>>

SHIN, Jongju; LEE, Jin; KIM, Daijin. Real-time lip reading system for isolated Korean word recognition. **Pattern Recognition**, 2011.

SIEBRA LOPES, Gustavo et al. Recognition of handwritten digits using the signature features and Optimum-Path Forest Classifier. **IEEE Latin America Transactions**, v. 14, n. 5, p. 2455–2460, 2016. Disponível em: <<http://ieeexplore.ieee.org/document/7530445/>>

SILVA, Adelino Pinheiro. **Modelos Ocultos de Markov**. Disponível em: <https://www.researchgate.net/publication/272350095_Modelos_Ocultos_de_Markov>. Acesso em: 20 jun. 2019.

SINGER, Robert N. **Motor learning and human performance**. 3. ed. New York: Macmillan, 1975.

SINGLA, Abhik; ROY, Partha Pratim; DOGRA, Debi Prosad. Visual rendering of shapes on 2D display devices guided by hand gestures. **Displays**, 2019.

SOARES, Gabriel Anísio dos Santos; COSTA, Maércio Rannieri Lima; MATOS, Leonardo Nogueira. **Implementação de treinamento de HMM com os algoritmos Forward, Backward e Viterbi**. São Cristóvão - SE. Disponível em: <<http://www.lbd.dcc.ufmg.br/colecoes/wticgerbase/2015/010.pdf>>. Acesso em: 19

jun. 2018.

SPARROW, W. A.; SHERMAN, Cheyne. Visual Expertise in the Perception of Action. **Exercise and Sport Sciences Reviews**, v. 29, n. 3, p. 124–128, 2001. Disponível em: <https://insights.ovid.com/crossref?an=00003677-200107000-00007>

SUTOPO, Joko et al. Gesture recognition of dance using chain code and hidden markov model. **International Journal of Advanced Trends in Computer Science and Engineering**, v. 8, n. 6, p. 3194–3199, 2019.

TAGUCHI, Shun; KOIDE, Satoshi; YOSHIMURA, Takayoshi. Online Map Matching with Route Prediction. **IEEE Transactions on Intelligent Transportation Systems**, v. 20, n. 1, p. 338–347, 2019.

TAN, B. Manipulating resistance training program variables to optimize maximum strength in men: a review. **J Strength Cond Res.**, v. 13, n. 3, p. 289-304, 1999.

TRAN, Cuong; DOSHI, Anup; TRIVEDI, Mohan Manubhai. Modeling and prediction of driver behavior by foot gesture analysis. **Computer Vision and Image Understanding**, 2012.

URGO, Marcello; TARABINI, M.; TOLIO, Tullio. A human modelling and monitoring approach to support the execution of manufacturing operations. **CIRP Annals**, 2019.

VALVERDE, Rafael Nicchio; PEREIRA, Flavio Garcia; VASSALLO, Raquel Frizera. Reconhecimento de gestos dinâmicos usando modelos ocultos de Markov para interação homem máquina. In: Anais do **X Simpósio Brasileiro de Automação Inteligente**. Universidade Federal de São João del-Rei, São João del-Rei, MG, Brasil. setembro 2011., pp. 438-443.

VAN, Bao Ly; GARCIA-SALICETTI, Sonia; DORIZZI, Bernadette. On using the Viterbi path along with HMM likelihood information for online signature verification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, v. 37, n. 5, p. 1237–1247, 2007.

VAN DEN BERGH, Frans; LALIOTI, V. Software chroma keying in an immersive virtual environment: research article. **South African Computer Journal**, 1999.

VANDEBURGH, Paul M.; MAHAR, Matthew T.; CHOU, Chia Hao. Allometric Scaling of Grip Strength by Body Mass in College-Age Men and Women. **Research Quarterly for Exercise and Sport**, 1995.

VILDJOUNAITE, E. et al. Unobtrusive assessment of stress of office workers via analysis of their motion trajectories. **Pervasive and Mobile Computing**, 2019.

WANG, Sy Bor et al. Hidden Conditional Random Fields for Gesture Recognition. **2006 IEEE Computer Society Conference On Computer Vision And Pattern Recognition - Volume 2 (cvpr'06)**, New York, USA, p.1-7, 2006. IEEE. <http://dx.doi.org/10.1109/cvpr.2006.132>.

WONDERSHARE. **Wondershare Filmora**. 2019. Disponível em:
<<https://filmora.wondershare.com/pt-br/>>. Acesso em: 13 dez. 2019.

YAMADA, Keita et al. Motor Skill Development Using Motion Recognition based on an HMM. **Procedia Computer Science**, v. 22, p.1112-1120, 2013. Elsevier BV.
<http://dx.doi.org/10.1016/j.procs.2013.09.197>.

YAMATO, J.; OHYA, J.; ISHII, K.. Recognizing human action in time-sequential images using hidden Markov model. **Proceedings 1992 IEEE Computer Society Conference On Computer Vision And Pattern Recognition**, Yokosuka, Japan, p.379-385, 1992. IEEE Comput. Soc. Press.
<http://dx.doi.org/10.1109/cvpr.1992.223161>.

YANG, L.; WIDJAJA, B. K.; PRASAD, R. Application of hidden Markov models for signature verification. **Pattern Recognition**, 1995.

YANG, Tsung Hsien et al. Coupled HMM-based multimodal fusion for mood disorder detection through elicited audio–visual signals. **Journal of Ambient Intelligence and Humanized Computing**, 2017.

ZHANG, Tao; LUO, Xiaohui; ZHU, Xiaojuan. License plate location based on singular value feature. **2010 3rd International Conference On Computer Science And Information Technology**, p. 283 - 287, jul. 2010. IEEE.
<http://dx.doi.org/10.1109/iccsit.2010.5564909>.

ZHU, Haibei et al. Operator Strategy Model Development in UAV Hacking Detection. **IEEE Transactions on Human-Machine Systems**, v. 49, n. 6, p. 540–549, 2019.

ZHUANG, Xiaodan et al. Face age estimation using patch-based hidden Markov model supervectors. In: 2008, **Anais...** : Institute of Electrical and Electronics Engineers (IEEE), 2008.

ZIMMERMANN, M.; MEHDIPOUR Ghazi M.; EKENEI H.K.; THIRAN JP. Visual Speech Recognition Using PCA Networks and LSTMs in a Tandem GMM-HMM System. In: **Chen CS., Lu J., Ma KK. (eds) Computer Vision – ACCV 2016 Workshops. ACCV 2016**. Lecture Notes in Computer Science, vol 10117. Springer, Cham.