

# MODELO DE ESTADOS PARA INFERÊNCIA DE ATIVIDADES HUMANAS BASEADO NA ASSOCIAÇÃO DE MOVIMENTOS OBTIDOS COM SISTEMAS DE VISÃO

DENNIS ROMERO LÓPEZ,\* ANSELMO FRIZERA NETO,\* TEODIANO FREIRE BASTOS\*

\**Universidade Federal do Espírito Santo,  
Av. Fernando Ferrari 514, Campus Goiabeiras,  
Vitória, ES, Brasil*

Emails: dennis@ele.ufes.br, anselmo@ele.ufes.br, tfbastos@ele.ufes.br

**Abstract**— This paper presents an approach to the problem of human activity inference, based on tracking actions or bodily expressions recognized by a computer vision system. A model based on recurrent neural networks is introduced in order to represent states, allowing the prediction of activities initially learned by the system. The proposed model considers the influence of a new global movement pattern. Thus, an activity can be inferred considering the presence of other actions that do not belong to the activity, as occurs in natural situations in human nonverbal communication.

**Keywords**— Computer Vision, Recurrent Neural Networks, HMM, Inference of Human Activities.

**Resumo**— Neste trabalho apresenta-se uma abordagem ao problema da inferência de atividades humanas, baseado no seguimento de ações ou expressões corporais reconhecidas por um sistema de visão computacional. Apresenta-se um modelo baseado em redes neurais recorrentes para a representação de estados, permitindo a predição de atividades inicialmente aprendidas pelo sistema. O modelo proposto considera a influência global de um novo padrão de movimento. Desta forma, uma atividade pode ser inferida considerando a presença de outras ações que não pertencem à atividade, como acontece em situações naturais na comunicação não verbal humana.

**Keywords**— Visão computacional, Redes Neurais Recorrentes, HMM, Inferência de atividades humanas.

## 1 Introdução

O presente trabalho detalha uma metodologia para estimação ou inferência de atividades humanas baseada na associação de expressões corporais capturadas por um sistema de visão computacional. Uma atividade é definida, neste contexto, como um conjunto de ações, movimentos ou expressões corporais que a pessoa realizou (ou decidiu realizar) dentro de um determinado ambiente.

A inferência de atividades humanas é um dos mais interessantes enfoques na área de aprendizado de máquinas e está relacionada com a compreensão das ações além do reconhecimento isolado de movimentos ou expressões corporais. No entanto, no campo da interação homem-máquina o aprendizado automático no nível do entendimento complexo apresenta diversos desafios. Entre eles, encontra-se a determinação de diferentes variáveis presentes no desenvolvimento de soluções que considerem a complexidade da comunicação não-verbal humana.

Neste sentido, um sistema de análise de atividades humanas que funcione em locais fechados poderia não funcionar em locais abertos, ou, determinada técnica que permite uma interação uni-pessoal pode não ser ajustável a uma versão multi-pessoal, etc. Esta é uma das razões pela qual técnicas robustas para todo tipo de ambiente, no que se refere às atividades humanas, são ainda problemas não resolvidos.

Dentro das vias de solução aos problemas antes mencionados, neste artigo aborda-se a representação de informação de movimento em modelos de estado que não assumam dependências exclusivas do estado anterior, como no caso da utilização de Modelos Ocultos de Markov (HMM), entre outras considerações que

serão mencionadas na seção 3. Dois enfoques principais são analisados (*Modelos Ocultos de Markov e Redes Neurais Recorrentes*), os quais foram identificados na revisão do estado da arte como tendências atuais na solução aos problemas relacionados com a análise automática de comportamento humano. Será detalhada a metodologia proposta para inferência de atividades baseada na representação de estados utilizando redes neurais recorrentes. Os métodos propostos foram implementados e integrados ao sistema de reconhecimento online de ações humanas, detalhado em Romero et al. (2012), conformando o sistema piloto denominado “*Emotion Viewer*”, para a inferência de emoções mediante a análise automática de expressões corporais relacionadas. Nas seções finais deste artigo são apresentados os resultados, conclusões e trabalhos futuros.

## 2 Trabalhos relacionados

A interação natural entre pessoas e computadores/robôs tem sido objeto de diversos estudos durante os últimos anos. A possibilidade de alcançar uma interação homem-máquina que ofereça uma experiência semelhante à interação natural entre pessoas é uma das principais motivações dos estudos atuais. Kim et al. fazem uma interessante introdução sobre o assunto em Kim et al. (2010).

Como mencionado na seção introdutória, existem diversos problemas relacionados com o reconhecimento de atividades humanas, entre eles: a dificuldade da categorização de ações; a realização de ações não descritivas ou irrelevantes no contexto do modelo das atividades; a recorrência (mais de uma atividade ao mesmo tempo); a interrupção temporal de

uma atividade e as possíveis ambiguidades de interpretação, devido à presença de ações comuns (ex. abrimos o forno para limpá-lo e para aquecer os alimentos).

Com o objetivo de abranger os problemas relacionados com o reconhecimento de atividades humanas, diferentes contribuições à literatura têm sido realizadas. Em Gu et al. (2011) propõe-se um enfoque baseado na identificação de Padrões Emergentes (em inglês *Emerging Patterns*) a partir da captura de informação de movimento com redes de sensores. O trabalho propõe uma metodologia que permite o reconhecimento de atividades recorrentes, interrompidas e também sequenciais. No entanto, apresenta limitações quanto à discriminação de ações, devido à redundância de informação no processo de captura. Outro enfoque similar é proposto em Khattak et al. (2010) orientado à supervisão de atividades de pessoas idosas de forma remota.

Embora a tecnologia relacionada com redes de sensores encontra-se em rápida evolução, sua utilização de forma generalizada apresenta ainda dificuldades. Por tal motivo, outros métodos de sensoriamento são considerados para a análise de ações e inferência de atividades humanas. O trabalho proposto em Piyathilaka e Kodagoda (2013) apresenta um enfoque baseado em Modelos Ocultos de Markov (HMM) e Modelo de Mistura de Gaussianas (GMM) para a inferência de atividades. As posições dos pontos correspondentes às uniões do esqueleto 3D de uma pessoa são capturadas mediante um sensor RGB-D. Dado que as uniões no modelo de esqueleto são normalizadas com respeito ao torso da pessoa, o método tende a um estado de inatividade quando a pessoa realiza poucos movimentos dos braços, dificultando uma análise mais robusta.

O trabalho proposto em Ryo (2011) aborda o enfoque da presente pesquisa, e está orientado à predição de atividades baseada na identificação de indícios ou intenções. Os indícios mencionados correspondem às ações isoladas reconhecidas em sequências de vídeo, permitindo a identificação antecipada de uma atividade. O trabalho mencionado utiliza histogramas integrais para determinar a probabilidade posterior da ocorrência de uma atividade, definida em (1),

$$P(A_p|O, t) = \sum_d P(A_p, d|O, t) = \frac{\sum_d P(O|A_p, d)P(t|d)P(A_p|d)}{\sum_i \sum_d P(O|A_i, d)P(t|d)P(A_i|d)}, \quad (1)$$

onde  $d$  corresponde à variável que descreve o nível de progresso da atividade  $A_p$ , dado um vídeo  $O$  de duração  $t$ . No referido trabalho o modelo estabelecido limita o número de atividades a serem reconhecidas. No trabalho aqui apresentado propõe-se um modelo que possa ser projetado para uma quantidade maior de atividades, considerando as características análogas a alguns modelos gráficos probabilísticos, intrínsecas às

redes neurais recorrentes (Sun et al., 1990; Mandic e Chambers, 2001).

### Aplicações da inferência de atividades

As aplicações para o reconhecimento de atividades têm uma ampla perspectiva de contribuição à sociedade, especialmente aquelas enfocadas às atividades do cotidiano, como por exemplo, no cuidado de idosos, análise da dinâmica corporal de pacientes psiquiátricos, segurança, entre outros.

Na área de segurança de pedestres, por exemplo, é onde é possível, de forma empírica, realizar a identificação de atitudes seguras ou inseguras de pessoas na hora de atravessar a rua. Neste sentido, um sistema automático poderia prever situações de risco ocasionadas por alguém que encontra-se realizando ações consideradas inseguras (Figura 1). Assim, o pedestre, e inclusive os motoristas próximos, poderiam ser alertados sobre um possível risco.

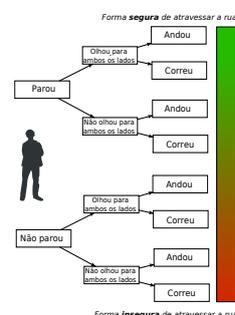


Figura 1: Diagrama ilustrativo de atitudes seguras e inseguras de atravessar a rua.

No entanto, para o desenvolvimento de aplicações como a mencionada, assim como em outras aplicações que envolvem o entendimento das ações humanas, é preciso estabelecer modelos que abordem a complexidade natural das ações envolvidas, considerando as variáveis que influenciam nas mesmas (objetivos, cultura, ambiente, etc.), assim como o espaço temporal (duração de uma ação) e não temporal (independência da ordem de aparecimento) que as envolve.

Na seguinte seção, realiza-se uma avaliação crítica dos Modelos Ocultos de Markov (HMM), os quais têm uma ampla aceitação na literatura de reconhecimento de padrões (Chen e Aggarwal, 2011; Jalal et al., 2012; Piyathilaka e Kodagoda, 2013), e por sua relação com o critério a ser detalhado nas seções posteriores sobre a inferência de atividades considerando redes neurais recorrentes (Guo e Zhang, 2012; Nishide et al., 2012).

### 3 Generalidades dos modelos preditivos para a inferência de atividades humanas

Como mencionado anteriormente, neste trabalho detalha-se o critério adotado para a estimação de atividades de uma pessoa, tomando como base o reconhecimento individual de ações por parte de um sis-

tema de visão computacional. A Figura 2 mostra, na parte superior, os blocos correspondentes ao processo de reconhecimento de ações, iniciando desde a captura de informação visual até sua caracterização e classificação. Estas ações alimentam o modelo associativo (parte inferior do diagrama), para a estimação das atividades possíveis.

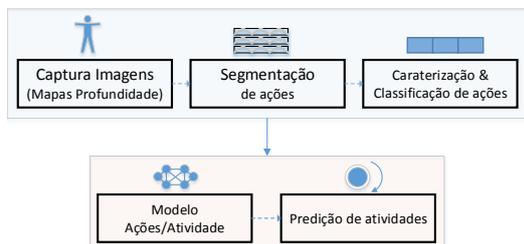


Figura 2: Diagrama geral da metodologia proposta (parte superior: processo de reconhecimento de ações; parte inferior: processo de inferência de atividades).

### HMM e Redes Neurais Recorrentes

Os Modelos Ocultos de Markov (em inglês, *Hidden Markov Models - HMM*) têm sido amplamente usados no reconhecimento sequencial de dados, especialmente no processamento de sinais de fala. Os HMM conformam um modelo linear, e são chamados de “ocultos” devido a que envolvem um processo estocástico (a sequência de estados) que não é observável, mas afeta a sequência de eventos observados (Rabiner, 1989).

A diferença fundamental entre HMM e várias das técnicas baseadas em critérios Markovianos, como as detalhadas em Ephraim e Roberts (2009), Tu e Zhu (2002) e Derrode e Pieczynski (2004), está na forma de observar o sistema. Na maioria dos processos Markovianos a observação é direta, devido a que os eventos observáveis são os próprios estados, enquanto que em HMM a observação é indireta, feita por inferência, sendo os eventos observáveis funções probabilísticas dos estados de Markov ou das transições entre esses estados. A Figura 3 mostra um diagrama simples de três estados ilustrando as probabilidades de transição (Rabiner, 1989).

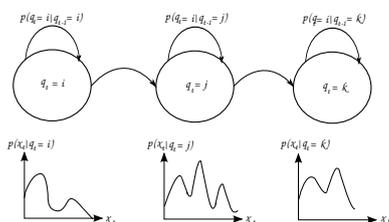


Figura 3: Exemplo de HMM simples de três estados

No entanto, as suposições que fazem possível a eficiência de HMM e sua otimização limitam sua generalidade. Como consequência, elas também sofrem de várias desvantagens, como as mencionadas em Bourlard e Bengio (2002):

- Pobre discriminação devido ao algoritmo de treinamento, o qual maximiza a verossimilhança em lugar das probabilidades a posteriori.
- Uma escolha a priori da topologia do modelo e distribuições estatísticas, ou seja, assumir que as funções de densidade de probabilidade associadas com os estados em HMM podem ser descritas como (misturas de) densidades Gaussianas Multivariadas, cada uma com uma matriz de covariância diagonal (ex. no sinal de fala, a possível correlação entre os componentes dos vetores acústicos é desconsiderada).
- Assume-se que a sequência de estados são cadeias de Markov de primeira ordem (as probabilidades de emissão e transição dependem só do estado atual).
- Assume-se que as observações de entrada não estão correlacionadas no tempo. Deste modo, considerando a topologia de HMM, a possível correlação temporal produto das características associadas dentro de um mesmo estado é simplesmente ignorada.

Com o objetivo de superar alguns destes problemas, vários pesquisadores concordam com a integração de redes neurais artificiais ao formalismo das HMMs. Neste sentido, as redes neurais recorrentes podem ser utilizadas também para codificar e reconhecer padrões em estruturas sequenciais. O estudo realizado por Sun et al. (Sun et al., 1990) mostra como as HMMs podem ser considerados como um caso especial de redes neurais recorrentes de segunda ordem, onde o algoritmo Baum-Welch comumente utilizado em HMM pode ser utilizado na aprendizagem de uma rede neural recorrente linear.

Nas redes neurais recorrentes não se distingue entre variáveis de entrada e variáveis de saída porque a saída de um neurônio (unidade de processamento) pode servir como entrada realimentada do mesmo neurônio. O conjunto de valores de saída atuais dos neurônios chama-se o *estado* da rede. Com os padrões de atividade neural representando estados internos de um sistema de evolução temporal, as iterações de uma rede neural recorrente representam a dinâmica sequencial do sistema (Raubert, 2005). Com este tipo de rede, pode-se recuperar informação memorizada, mesmo com informação inicial incompleta, corrompida ou parcialmente errada. Neste trabalho, propõe-se a utilização de redes neurais recorrentes lineares como alternativa ao uso de HMM, na aplicação específica da inferência de atividades humanas.

Um exemplo de rede recorrente é o modelo proposto por Hopfield (Hopfield et al., 1986), que introduziu uma representação matemática inspirada no funcionamento biológico dos neurônios cerebrais, permitindo aos computadores ter a capacidade de “lembrar” padrões previamente aprendidos. O modelo de Hopfield tem sido amplamente citado na literatura e deu lugar a novos enfoques baseados na conexão

recorrente de neurônios artificiais, para uma diversidade de aplicações, principalmente aquelas que fazem uso de *memória associativa*.

A finalidade da rede é memorizar  $n$  padrões  $\underline{x}_p$  de um conjunto de padrões  $T = \{\underline{x}_p\}_{p=1}^n$ . A rede tem que responder nas saídas com o estado  $x_{(t)} = \underline{x}_p$ , quando esse mesmo estado for apresentado inicialmente à rede, ou seja,  $x_{(0)} = \underline{x}_p$ . A resposta deveria ser também o padrão memorizado, mesmo se o estímulo inicial somente for semelhante a um dos padrões memorizados, ou seja  $x_{(0)} \approx \underline{x}_p$ , considerando a semelhança entre dois padrões binários  $\underline{x}_p = (x_{p1}, \dots, x_{pH})^T$  e  $\underline{x}_q = (x_{q1}, \dots, x_{qH})^T$  como uma medida de distância entre eles. No trabalho aqui apresentado, esta medida é obtida utilizando a distância de Hamming entre os padrões (Mandic e Chambers, 2001).

Embora outras técnicas presentes na literatura consideram diferentes enfoques preditivos, como é o caso de POMDP (em inglês *Partially Observable Markov Decision Process*), este trabalho busca apresentar algumas diferenças estruturais de ambos os enfoques preditivos referidos inicialmente, na justificativa da metodologia a seguir.

#### 4 Metodologia proposta

Após a identificação de ações da pessoa realizada por um sistema de reconhecimento, como o detalhado em Romero et al. (2012), a inferência de atividades (com uma relação ações-atividade previamente definida) é realizada mediante um modelo de estados representado pela rede neural recorrente. Os modelos mostrados a seguir estão baseados na rede de Hopfield, na qual os estados estáveis são determinados na etapa de treinamento. A informação a ser treinada corresponde a padrões de dimensão 6, e suas características podem ter dois valores possíveis, 1 e -1, como mostra a Figura 4.

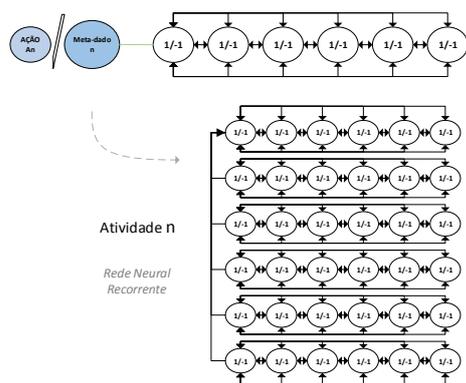


Figura 4: Ilustração da composição de uma ação ou informação de contexto relacionada (acima) e distribuição de neurônios para o aprendizado de atividades (abaixo).

A dimensão dos padrões mencionados foi estabelecida seguindo uma representação baseada na tabela

de caracteres ASCII de seis bits, a qual permitiu simular a identificação de até  $2^6$  ações possíveis.

Considerando a dimensão dos padrões escolhidos, conseguiu-se a identificação de até 36 atividades (descartando repetições que possam favorecer a ponderação de alguma ação em particular). Cabe mencionar que ações possíveis, assim como o número de atividades a reconhecer, crescem exponencialmente com o incremento do tamanho do padrão selecionado.

O custo computacional deste tipo de rede é um aspecto que tem sido amplamente discutido na literatura. No entanto, novas técnicas baseadas em matriz esparsa e abordagens de processamento usando GPU (Graphics Processing Unit) (Yao et al., 2013), (Stroffek e Marsalek, 2012), fazem do método proposto neste trabalho uma abordagem aplicável a circunstâncias atuais.

As combinações balanceadas (não repetidas) dos padrões na rede permitem a distribuição equitativa das probabilidades de cada estado. No entanto, durante o processo de treino, estas probabilidades são balanceadas em favor do estado mais ativo. Neste sentido, e em correspondência à configuração da rede na Figura 4, se para uma atividade  $Act_x$ , uma ação repetisse mais de uma vez, esta ação terá um peso maior para descrever a própria atividade e terá influência na totalidade da rede. Desta forma, é possível manter a estimativa correta na presença de ações que não pertencem à atividade sendo executada.

Esta é uma propriedade essencial desde o ponto de vista da computação ubíqua, considerando que cada pessoa pode realizar ações diferentes durante a realização de uma mesma atividade, incluindo aquelas que formam parte de outras previamente treinadas (Figura 5). A rede valoriza ações representativas dentro de uma atividade em particular. Assim, as atividades candidatas podem mudar repentinamente durante o aparecimento de uma ação com peso maior, no âmbito de todas as atividades aprendidas.

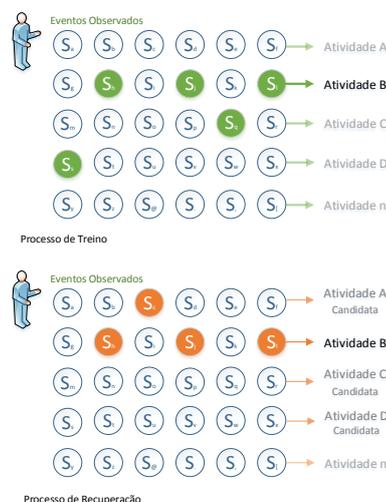


Figura 5: Exemplo de ativação de estados para a previsão de atividades.

Na fase de “recuperação” (termo adotado para as redes neurais com propriedades de memória associativa) (Stroffek e Marsalek, 2012), as ações reconhecidas pelo sistema de visão computacional, ativarão seu estado correspondente na rede em cada uma das atividades, aproximando-se com cada nova ação à “forma” treinada da mesma. As variações de “forma” do padrão estimado são comparadas com os padrões treinados usando uma medida de distância de Hamming (Mandic e Chambers, 2001) para cada nova ação apresentada à rede.

## 5 Resultados

A implementação da metodologia descrita na seção anterior deu lugar ao desenvolvimento do sistema de reconhecimento de emoções denominado “Emotion Viewer”. Este sistema integra os resultados obtidos em Romero et al. (2012) para a identificação on-line de movimentos humanos, servindo como base para os métodos propostos neste trabalho. A Figura 6 apresenta a captura de tela de diferentes partes do sistema, entre eles as imagens expressivas que são mostradas ao usuário; os padrões de movimento gerados pelo sistema de reconhecimento online de expressões corporais (Romero et al., 2012); e a convergência do modelo ao estado mais provável.



Figura 6: Captura de tela das diferentes etapas do sistema integrado “Emotion Viewer”.

A Figura 7 mostra um exemplo do processo de recuperação de informação para a predição de uma atividade. À medida que uma nova ação é reconhecida pelo sistema de visão, a rede apresenta um novo padrão baseado no nó mais representativo, identificado no processo de treino. O padrão resultante é comparado com outros padrões possíveis usando medições

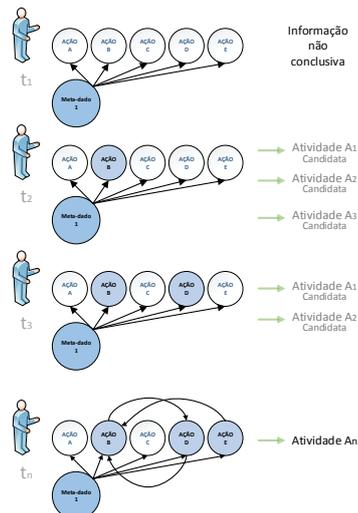


Figura 7: Exemplo do processo de recuperação de informação da atividade em função das ações e dados do ambiente identificados.

da distância de Hamming. Valores de distância entre o padrão resultante e os padrões candidatos fora de um limiar predefinido são considerados como informação não conclusiva, colocando a interface do usuário à espera de um novo gesto ou ação.

## 6 Conclusões

Neste trabalho apresentou-se um enfoque para inferência de atividades humanas baseado na associação de movimentos reconhecidos com um sistema de visão computacional. Duas abordagens principais foram analisadas (*Modelos Ocultos de Markov e Redes Neurais Recorrentes*), as quais foram identificadas na revisão do estado da arte como tendências atuais na solução de problemas relacionados com a análise automática de comportamento humano. Adicionalmente, foi proposta uma técnica para inferência de atividades, que considera ações preponderantes e que incorpora o suporte de duas propriedades comuns, presentes nas tarefas cotidianas humanas: a primeira, o fato de que várias pessoas podem executar diferentes ações na realização de uma mesma atividade; e a segunda, a inclusão de informação contextual, a qual influi no critério de decisão durante a inferência automática de atividades do cotidiano.

Detalhou-se o contexto no qual o uso de redes neurais recorrentes na representação de ações humanas podem contribuir na adaptação do sistema a situações com um considerável nível de complexidade desde o ponto de vista dos modelos ocultos de Markov.

O modelo proposto valoriza ações representativas dentro de uma atividade em particular. Desta forma, as atividades candidatas podem mudar repentinamente durante o aparecimento de uma ação com peso maior, no âmbito de todas as atividades aprendidas.

O entendimento automático de ações e expressões corporais humanas tem implicações diretas na forma de interagir com os computadores. A robótica de

serviços é uma das mais promissoras áreas de aplicação. Neste contexto, aplicações de supervisão, interfaces com interação natural, reabilitação física, comunicação e segurança, são possibilidades a serem consideradas. Detectores automáticos de emoções e estados de ânimo, incluindo fadiga, depressão e ansiedade, poderiam também conformar um passo importante para o bem-estar pessoal e para as tecnologias assistivas.

### Agradecimentos

Este Projeto de Pesquisa é financiado pelo Programa Primeiros Projetos, Edital CNPq/FAPES No. 02/2011, e pelo CNPq, através de bolsa de doutorado para o primeiro autor.

### Referências

- Bourlard, H. e Bengio, S. (2002). *Hidden markov models and other finite state automata for sequence processing*, The MIT Press.
- Chen, C.-C. e Aggarwal, J. (2011). Modeling human activities as speech, *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, pp. 3425–3432.
- Derrode, S. e Pieczynski, W. (2004). Signal and image segmentation using pairwise markov chains, *Signal Processing, IEEE Transactions on* **52**(9): 2477–2489.
- Ephraim, Y. e Roberts, W. J. J. (2009). An em algorithm for markov modulated markov processes, *Signal Processing, IEEE Transactions on* **57**(2): 463–470.
- Gu, T., Wang, L., Wu, Z., Tao, X. e Lu, J. (2011). A pattern mining approach to sensor-based human activity recognition, *Knowledge and Data Engineering, IEEE Transactions on* **23**(9): 1359–1372.
- Guo, D. e Zhang, Y. (2012). Novel recurrent neural network for time-varying problems solving [research frontier], *Computational Intelligence Magazine, IEEE* **7**(4): 61–65.
- Hopfield, J. J., Tank, D. W. et al. (1986). Computing with neural circuits- a model, *Science* **233**(4764): 625–633.
- Jalal, A., Uddin, M. e Kim, T. S. (2012). Depth video-based human activity recognition system using translation and scaling invariant features for life logging at smart home, *Consumer Electronics, IEEE Transactions on* **58**(3): 863–871.
- Khattak, A., Pervez, Z., Ho, K. K., Lee, S. e Lee, Y.-K. (2010). Intelligent manipulation of human activities using cloud computing for u-life care, *Applications and the Internet (SAINT), 2010 10th IEEE/IPSJ International Symposium on*, pp. 141–144.
- Kim, E., Helal, S. e Cook, D. (2010). Human activity recognition and pattern discovery, *Pervasive Computing, IEEE* **9**(1): 48–53.
- Mandic, D. P. e Chambers, J. (2001). *Recurrent neural networks for prediction: Learning algorithms, architectures and stability*, John Wiley & Sons, Inc.
- Nishide, S., Tani, J., Okuno, H. e Ogata, T. (2012). Self-organization of object features representing motion using multiple timescales recurrent neural network, *Neural Networks (IJCNN), The 2012 International Joint Conference on*, pp. 1–8.
- Piyathilaka, L. e Kodagoda, S. (2013). Gaussian mixture based hmm for human daily activity recognition using 3d skeleton features, *Industrial Electronics and Applications (ICIEA), 2013 8th IEEE Conference on*, pp. 567–572.
- Rabiner, L. (1989). A tutorial on hidden markov models and selected applications in speech recognition, *Proceedings of the IEEE* **77**(2): 257–286.
- Rauber, T. W. (2005). Redes neurais artificiais, *Departamento de informática-Universidade Federal do Espírito Santo*.
- Romero, D., Vintimilla, B., Frizera, A. e Bastos, T. (2012). Rwe patterns extraction for on-line human action recognition through window-based analysis of invariant moments, *Robocontrol (2012)*, Bauru -SP.
- Ryoo, M. S. (2011). Human activity prediction: Early recognition of ongoing activities from streaming videos, *Computer Vision (ICCV), 2011 IEEE International Conference on*, pp. 1036–1043.
- Stroffek, J. e Marsalek, P. (2012). Short-term potentiation effect on pattern recall in sparsely coded neural network, *Neurocomputing* **77**(1): 108–113.
- Sun, G., Chen, H., Lee, Y. e Giles, C. (1990). Recurrent neural networks, hidden markov models and stochastic grammars, *Neural Networks, 1990., 1990 IJCNN International Joint Conference on*, pp. 729–734.
- Tu, Z. e Zhu, S.-C. (2002). Image segmentation by data-driven markov chain monte carlo, *Pattern Analysis and Machine Intelligence, IEEE Transactions on* **24**(5): 657–673.
- Yao, Z., Gripon, V. e Rabbat, M. (2013). A massively parallel associative memory based on sparse neural networks, *arXiv preprint arXiv:1303.7032*.