

Modelos Ocultos de Markov Aplicados na Identificação de Comportamento de Camundongos

Jonathan de Andrade Silva, Wesley Nunes Gonçalves, Bruno Brandoli Machado, Hemerson Pistori, Albert Schiaveto de Souza

¹Universidade Católica Dom Bosco – UCDB,
Av. Tamandaré, 6000, Jardim Seminário,
Campo Grande, MS, Brasil, 79117-900

{bmachado, jsilva, wnunes}@acad.ucdb.br, {pistori, albert}@ucdb.br

Abstract. *The application of hidden models of Markov (HMM) has been frequently used in behaviors recognition system. In this paper the HMM is applied for recognition of three mice behaviors: self-cleaning, horizontal and vertical exploration. There were carried out experiments with the variations of some parameters of the model, where a percentage of correct classification of 80,3% was obtained.*

Resumo. *A aplicação de modelos ocultos de Markov (HMM) tem sido frequentemente utilizada em sistemas de reconhecimento de comportamentos. Neste trabalho é aplicado o HMM para reconhecimento de três comportamentos de camundongos: auto-limpeza, exploração vertical e horizontal. Foram realizados experimentos com as variações de alguns parâmetros do modelo, onde foi obtida uma porcentagem de classificação correta dos comportamentos de 80,3%.*

1. Introdução

O estudo do comportamento animal é muito utilizado por indústrias farmacêuticas, para serem analisadas as reações de determinados fármacos. O uso de animais de laboratório em pesquisas, em particular os camundongos, serve de modelo simplificado do comportamento humano [Fagundes and Taha 2004]. Com isso, os camundongos tornaram-se fundamentais na avaliação de novos fármacos para que sejam testados antes de serem aplicados em seres humanos.

Em grande parte das pesquisas o estudo do comportamento animal é feito de forma manual. O método de observação manual exige do observador humano uma grande demanda de tempo e concentração, o que torna exaustivo para os pesquisadores a execução dos experimentos, podendo influenciar nos registros das informações, conseqüentemente podendo afetar os resultados dos experimentos.

Atualmente houve um pequeno aumento em pesquisas para o desenvolvimento de sistemas que automatizem o método de identificação do comportamento animal, através de imagens digitalizadas [Machado et al. 2006]. Muitos desses sistemas que realizam a identificação dos comportamentos de animais utilizam recursos da área de visão computacional [Forsyth and Ponce 2002] e reconhecimento de padrões [Theodoridis and Koutroumbas 1999].

Neste trabalho foi utilizada uma técnica de descrição de forma baseada em região conhecida como momentos de imagens. Dentre as técnicas de classificação existentes foi proposta neste artigo a técnica baseada em modelos estatísticos conhecido como Modelos Ocultos de Markov (Hidden Markov Models)[Rabiner 1989]. O HMM foi empregado na classificação dos comportamentos dos camundongos, auxiliando em pesquisas que realizem experimentos com esses animais. Neste trabalho foi utilizado o HMM de observações discretas para a classificação dos comportamentos dos camundongos de auto-limpeza, exploração vertical e horizontal. Os parâmetros avaliados neste modelo foram o número de estados e o número de iterações para a estimação dos parâmetros do modelo, pela porcentagem de acerto e tempo de execução.

Este artigo está organizado como segue. A seção 2 apresenta os trabalhos que utilizam HMM e na Seção 3 descrevemos o algoritmo de extração de característica de momentos de imagens. Na próxima seção, é descrito em detalhes o HMM utilizado neste trabalho. Na Seção 4 apresentamos os experimentos. Finalmente, na Seção 5 são discutidas as limitações e os pontos positivos do sistema.

2. Trabalhos Correlatos

Os modelos ocultos de Markov (hidden Markov models - HMM) têm sido amplamente utilizados em diversas áreas. Em [Hornegger et al. 1994] o HMM é aplicado ao reconhecimento de objetos 2D em imagens. O HMM, em conjunto com as características do contorno adquiridas dos objetos, foi utilizado na classificação de quatro diferentes tipos de objetos, com um conjunto de cinquenta imagens de treinamento cada. O sistema foi avaliado com dez imagens para cada tipo de objeto, a classificação resultou em uma taxa de acerto de 75%.

James em [Lien et al. 1999] utiliza os modelos de Markov ocultos para detecção de faces humanas, com observações discretas. No treinamento foi utilizado o algoritmo Baum-Welch, para obter os parâmetros do modelo. Em seus resultados com o modelo oculto de Markov foi obtida uma porcentagem de acerto de 92% na classificação de faces.

Liu em [Liu et al. 2004] apresenta vários meios de inicializar e treinar os HMM para reconhecimento de letras do alfabeto. Cada modelo é treinado com múltiplas seqüências de observações usando os algoritmos Baum-Welch e o Viterbi, utilizando de três estruturas de modelos HMM, o modelo *Fully-Connected*, *Left-Right* e *Left-Right Banded*. Com o algoritmo Viterbi e o modelo *Left-Right Banded* obtiveram um desempenho total de 97% na classificação dos gestos.

Em [Leo et al. 2004] utilizou os HMM para modelar os movimentos humanos para detectar movimentos suspeitos. Utilizando o algoritmo BCLS foram detectadas quatro classes diferentes de posturas que então são introduzidas no HMM. Dessa forma, obtiveram uma média de acerto para classificação da postura de 86,87%.

Matetic em [Matetic and Ribaric 2002] utilizou o HMM para modelar o comportamento animal, utilizou a combinação dos métodos de aprendizagem supervisionada e não-supervisionada. Na aprendizagem não-supervisionada são obtidas as seqüências de símbolos ou observações. Na fase de aprendizagem supervisionada são analisados os símbolos obtidos da aprendizagem não-supervisionada para obtenção dos símbolos mais representativos. Obtiveram uma taxa de acerto de 95% para comportamentos cíclicos (*Cycling Motion*) e 85% para comportamentos lentos (*Slow Motion*).

3. Momentos de Imagem

Uma imagem pode ser visualizada como uma função 2D discreta I , onde a intensidade de cada *pixel* é indexada como $I(x, y)$. A Equação 1 é a derivação da fórmula para funções contínuas.

$$M_{pq} = \sum_{x=1}^{width} \sum_{y=1}^{height} x^p y^q I(x, y) \quad (1)$$

Através dos momentos de imagens é possível derivar algumas propriedades dos objetos, como por exemplo, a área é representada pelo momento M_{00} e o centro de massa $\bar{x}$ e $\bar{y}$ é representado pelos momentos $\frac{M_{10}}{M_{00}}$, $\frac{M_{01}}{M_{00}}$, respectivamente.

Além dos momentos regulares, é possível derivar os momentos centrais para imagens, definido na Equação 2.

$$u_{pq} = \sum_{x=1}^{width} \sum_{y=1}^{height} (x - \bar{x})^p (y - \bar{y})^q I(x, y) \quad (2)$$

As propriedades derivadas dos momentos centrais neste trabalho são as variâncias em X e Y (Equação 3), a direção do objeto (Equação 4) e a excentricidade (Equação 5)

$$\sigma_x^2 = \frac{u_{20}}{m_{00}}, \quad \sigma_y^2 = \frac{u_{02}}{m_{00}} \quad (3)$$

$$\theta = \frac{u_{02} - u_{20} - 2u_{11} + \lambda}{u_{02} - u_{20} + 2u_{11} - \lambda} \quad (4)$$

$$e^2 = \frac{u_{20} + u_{02} + \lambda}{u_{20} + u_{02} - \lambda} \quad (5)$$

$$\lambda = \sqrt{(u_{20} - u_{02})^2 + 4u_{11}^2} \quad (6)$$

Na Figura 1 é ilustrada a aplicação dos momentos em uma imagem contendo um camundongo. A imagem foi dividida em quatro quadrantes com a mesma área, em seguida, para cada quadrante são extraídos o centro de massa e o desvio, ilustrados como eixos. Além desses parâmetros, para a imagem como um todo, são extraídos os parâmetros da elipse que representa o objeto.

4. Modelos Ocultos de Markov

Os modelos ocultos de Markov são compostos por um processo estocástico duplo. O primeiro processo é descrito por um conjunto de estados não diretamente observáveis, por isso, o nome desse modelo recebe a palavra oculto. A transição entre os estados depende apenas do estado anterior. Assim, a probabilidade de transição entre os estados desse modelo é representada através de uma matriz de transição $A = \{a_{ij}\}$ descrita na Equação 7.




Figura 1. Aplicação dos momentos de imagem.

$$a_{ij} = P(q_{t+1} = S_j | q_t = S_i) \quad 1 \leq i, j \leq N \quad (7)$$

sendo N o número de estados, q_t o estado atual e $S = \{S_1, S_2, S_3, \dots, S_N\}$ o conjunto de estados do modelo. Cada elemento a_{ij} da matriz de transição representa a probabilidade de mudança para um estado S_j no tempo $t + 1$ sabendo que no tempo t o estado era S_i .

Em algumas aplicações, os estados não são diretamente observados, com isso, cada estado é observado através de um segundo processo estocástico. A sequência de observações é representada por um conjunto $O = O_1, O_2, O_3, \dots, O_T$, onde cada elemento O_t representa um símbolo do conjunto finito de símbolos $V = v_1, v_2, \dots, v_M$ sendo M o número de símbolos. A probabilidade de emissão de símbolos em um estado j é definida na matriz $B = \{b_j(k)\}$ da Equação 8.

$$b_j(k) = P(O_t = v_k | q_t = S_j) \quad 1 \leq j \leq N, \quad 1 \leq k \leq M \quad (8)$$

A probabilidade inicial de cada estado é representada por um conjunto $\pi = \{\pi_i\}$ mostrada na Equação 9.

$$\pi_i = P(q_1 = S_i) \quad 1 \leq i \leq N, \quad \text{com} \quad \sum_{i=1}^N \pi_i = 1 \quad (9)$$

Neste trabalho foram aplicados os algoritmos para a solução de dois problemas básicos do HMM. O primeiro problema envolve o cálculo da probabilidade de uma sequência observada $O = O_1, O_2, \dots, O_T$ ser produzida por um modelo $\lambda = (A, B, \pi)$. Um dos procedimentos que resolve esse problema eficientemente, baseado na técnica de programação dinâmica, é o algoritmo *Forward* ou *Backward*. O segundo problema, considerado um dos mais difíceis do HMM, consiste em determinar um método para ajustar os parâmetros do modelo $\lambda = (A, B, \pi)$. Esse problema é solucionado através do algoritmo de *Baum-Welch* (especialização do algoritmo EM). A resolução desses dois problemas, conhecidos como problema de avaliação e aprendizagem, foi extensivamente descritas em diversos trabalhos na literatura [Montero and Sucar 2004, Starner and Pentland 1995].

5. Experimentos

Para iniciar a realização dos experimentos foi desenvolvido um banco de imagens referentes aos comportamentos dos camundongos classificados, composto de 210 imagens. Os



Figura 2. *Comportamentos realizados pelos camundongos.*

comportamentos identificados neste experimento foram o comportamento de auto limpeza, exploração vertical e horizontal, conforme mostrados na Figura 2. As imagens foram capturadas através de uma câmera IP *Wireless* TRENDNET modelo TV-IP301W, com resolução de 640 x 480 *pixels*.

As imagens contidas no banco de imagens foram inicialmente segmentadas pela técnica de subtração de fundo [Gonçalves et al. 2007]. Após a etapa de segmentação, as imagens foram pré-processadas e extraídas as informações a respeito de sua área, utilizando o algoritmo de momentos de imagens.

O equipamento utilizado foi um computador com processador Pentium 4TM com 3.00 GHz e 512 *MBytes* e o sistema operacional Ubuntu e a linguagem de programação Java versão 1.5. Para as implementações das técnicas foram utilizadas algumas funcionalidades das bibliotecas JMF¹, para manipulação de vídeos e imagens, ImageJ², para o processamento das imagens.

O tipo de modelo desenvolvido foi o HMM de observações discretas. Para a utilização desse tipo de modelo as observações adquiridas na etapa extração de características foram discretizadas através da técnica de quantização vetorial (*Vector Quantization LBG*) [Shen and Hasegawa 2006]. A melhor porcentagem de classificação correta é obtida através da variação dos parâmetros números de estados do HMM e o número de iterações do algoritmo de re-estimação. Além disso, o número de estados foi avaliado com relação ao tempo de execução. A variação dos parâmetros para o número de estados foi de 2 a 20, enquanto para a variação do número de iterações foi de 700 a 1000. Estas faixas de variação dos parâmetros foram selecionadas com base em um experimento inicial.

6. Resultados e Análises


O comportamento do gráfico da Figura 3(a) demonstra que com 10 estados foi obtido a melhor porcentagem de acerto na classificação dos comportamentos dos camundongos, chegando a 80.3 %. Na Tabela 1, é apresentada a relação do número de iterações pela porcentagem de classificação correta, nota-se que entre 800 e 1000 iterações a porcentagem de classificação tende-se a estabilizar, chegando a 70.46%, sendo utilizado para o

¹JMF - <http://java.sun.com/products/java-media/jmf/>


²ImageJ - rsb.info.nih.gov/ij/

Tabela 1. Relação número de iterações pela porcentagem de classificação correta.

Número de iterações	Classificação correta (%)
700	68.84
800	70.46
900	70.14
1000	70.32



(a) Variação do número de estados pela porcentagem de classificação correta dos comportamentos.



(b) Variação do número de estados pelo tempo de treinamento do modelo.

Figura 3. Gráficos do número de estados e tempo de treinamento.

treinamento através do algoritmo de Baum-Welch. O gráfico da Figura 3(b), apresenta um comportamento polinomial conforme aumentamos o número de estados para o modelo.

7. Conclusões e Trabalhos Futuros

A principal contribuição deste trabalho foi demonstrar a aplicação de modelos ocultos de Markov para o problema de identificação dos comportamentos de camundongos, e a escolha das variações dos parâmetros para atingir uma porcentagem de classificação correta máxima. Este sistema de classificação dos comportamentos dos camundongos será integrado ao sistema Topolino ³.

Os resultados obtidos foram satisfatórios, no entanto, podemos encontrar outras formas de maximizar a porcentagem de classificação correta dos camundongos. Como trabalhos futuros, serão propostos o desenvolvimento dos modelos ocultos de Markov do tipo contínuo com uma gaussiana e com mistura de gaussianas e realizar a comparação com o modelo discreto. Devido ao fato de no modelo discreto ao realizar a discretização das observações à perda de informação enquanto no modelo contínuo a natureza das informações obtidas no processo de aquisição é mantida. Outra proposta de trabalhos futuros é a aplicação do HMM para o reconhecimento de comportamento de outros animais.

8. Agradecimentos

Este trabalho recebeu apoio financeiro da Universidade Católica Dom Bosco, UCDB, da Agência Financiadora de Estudos e Projetos, FINEP e da Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia do Estado de Mato Grosso do Sul,

³Topolino - <http://www.gpec.ucdb.br/topolino>

FUNDECT. Um dos co-autores é bolsista de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora do CNPq e alguns dos outros co-autores receberam bolsas PIBIC/CNPq.

Referências

- Fagundes, D. J. and Taha, M. O. (2004). Modelo animal de doença: critérios de escolha e espécies de animais de uso corrente. *Acta Cirúrgica Brasileira*, 19:59–65.
- Forsyth, D. A. and Ponce, J. (2002). *Computer Vision: A Modern Approach*. Prentice Hall.
- Gonçalves, W. N., Saueia, V. A., Machado, B. B., de Andrade Silva, J., de Souza Padovani, K., and Pistori, H. (2007). Técnicas de segmentação baseadas em subtração de fundo e modelos de cores: Um estudo comparativo. *XXVIII CILAMCE - Iberian Latin American Congress on Computational Methods in Engineering*.
- Hornegger, J., Niemann, H., Paulus, D., and Schlottke, G. (1994). Object recognition using Hidden Markov Models. In Gelsema, E. S. and Kanal, L. N., editors, *Pattern Recognition in Practice IV: Multiple Paradigms, Comparative Studies and Hybrid Systems*, volume 16, pages 37–44, Amsterdam. Elsevier.
- Leo, M., D’Orazio, T., and Spagnolo, P. (2004). Human activity recognition for automatic visual surveillance of wide areas. In *VSSN 04 Proceedings of the ACM 2nd international workshop on Video surveillance & sensor networks*, pages 124–130, New York, NY, USA. ACM Press.
- Lien, J.-J. J., Kanade, T., Cohn, J., and Li, C. (1999). Detection, tracking, and classification of action units in facial expression. *Journal of Robotics and Autonomous Systems*.
- Liu, N., Davis, R. I. A., Lovell, B. C., and Kootsookos, P. (2004). Model structure selection and training algorithms for an hmm gesture recognition system.
- Machado, B. B., de Andrade Silva, J., Gonçalves, W. N., Pistori, H., and de Souza, A. S. (2006). Topolino: Software livre para automatização do experimento do campo aberto. *XV Seminário de Computação*, pages 19–28.
- Matetic, M. and Ribaric, S. (2002). A system for the behaviour analysis of laboratory animal based on qualitative modelling. In *Proceedings of the 6th International Conference on Intelligent Engineering Systems*, pages 273–278.
- Montero, J. A. and Sucar, L. E. (2004). Feature selection for visual gesture recognition using hidden markov models. In *ENC*, pages 196–203.
- Rabiner, L. R. (1989). A tutorial on hidden markov models and selected applications in speech recognition. In *Proceedings of the IEEE*, volume 77, pages 257–285.
- Shen, F. and Hasegawa, O. (2006). An adaptive incremental lbg for vector quantization. *Neural Netw.*, 19(5):694–704.
- Starner, T. and Pentland, A. (1995). Visual recognition of american sign language using hidden markov models. Technical Report Master’s Thesis, MIT, Program in Media Arts & Sciences, Massachusetts Institute of Technology, Cambridge, USA.
- Theodoridis, S. and Koutroumbas, K. (1999). *Pattern Recognition*. Academic Press, 1 edition.