

# **Um sistema de visão computacional bayesiano para modelagem de interações humanas**

---

**Um estudo sobre o trabalho de  
Nuria M. oliver, Barbara Rosario e Alex P. Pentland**

**Todos os créditos aos autores do estudo**

# Lógica Bayesiana



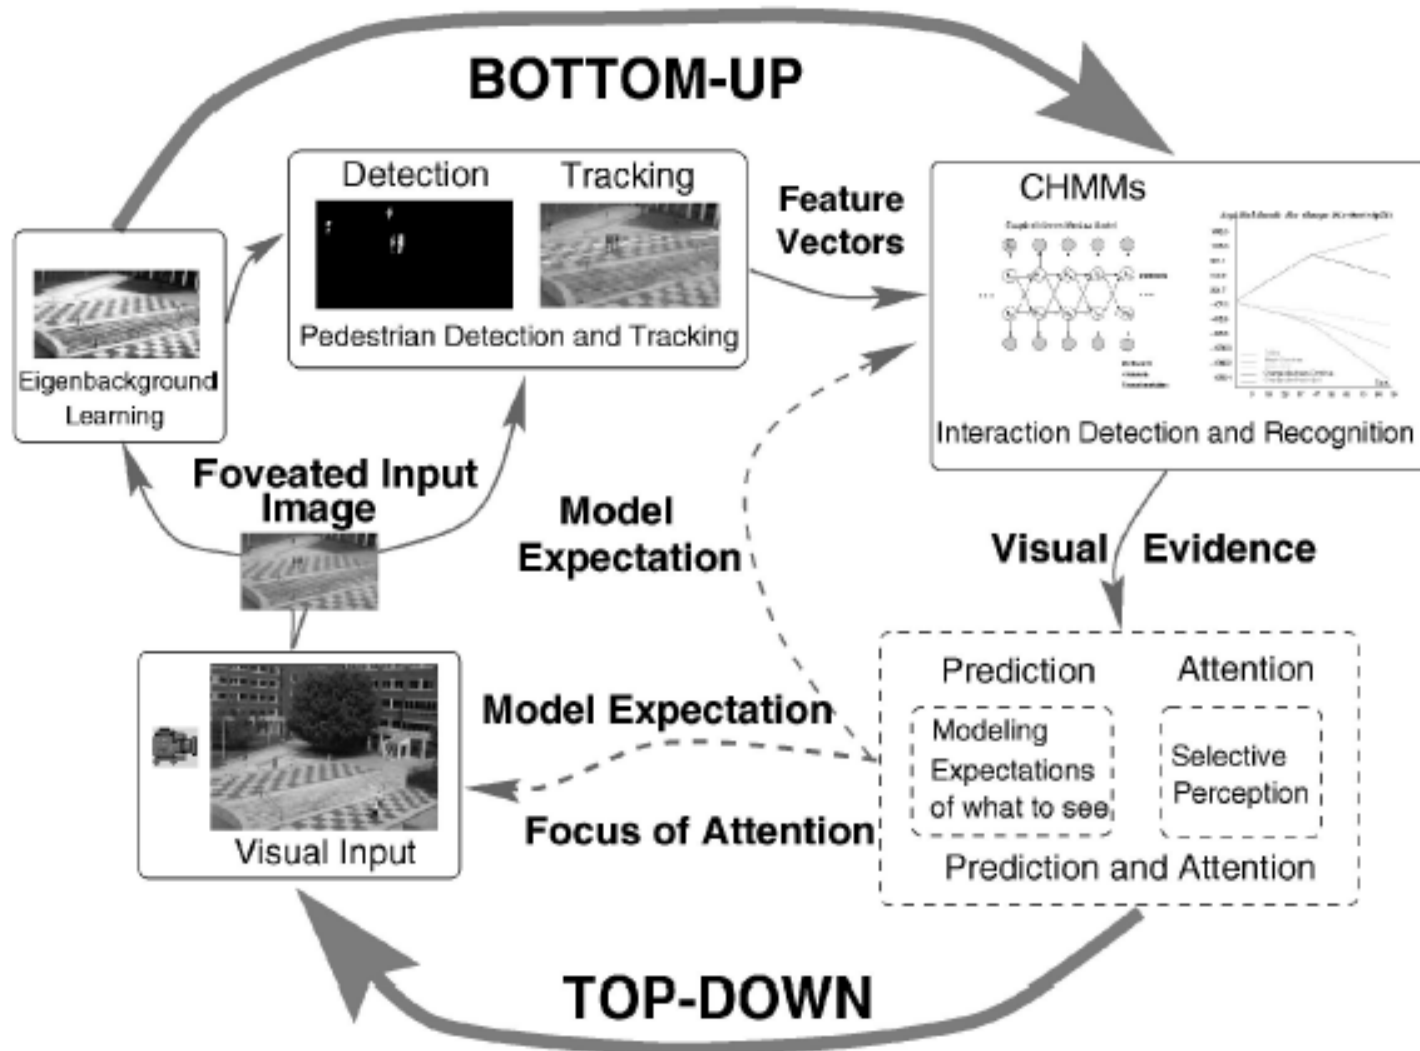
- <sup>1</sup>Nomeado para Thomas Bayes, um clérigo Inglês e matemático, lógica Bayesiana é um ramo da lógica aplicada à tomada de decisão e estatística inferencial que lida com probabilidade de inferência: usando o conhecimento dos eventos anteriores para prever eventos futuros.
- <sup>1</sup>Para demonstrar uma aplicação do teorema de Bayes, suponha que temos uma cesta coberta que contém três bolas, cada uma das quais pode ser verde ou vermelha. Em um teste cego tiramos uma bola vermelha. Nós devolvemos a bola ao cesto e tentamos de novo, mais uma vez tirando uma bola vermelha. Mais uma vez, voltamos a bola ao cesto e tiramos uma bola - vermelho novamente. Nós formamos uma hipótese de que todas as bolas são, de fato, vermelhas. Teorema de Bayes pode ser usado para calcular a probabilidade (P) de que todas as bolas são vermelhas (um evento rotulado como "A") dado que (simbolizado como a "|") todas as retiradas foram vermelhas (um evento rotulado como "B "):

○ 1

$$P (A | B) = p \{A\} + B / P \{B\}$$

<sup>1</sup>(<http://whatis.techtarget.com/definition/Bayesian-logic>)

# Loop de processamento



# Passos do Loop de Processamento



- 1. O módulo de entrada em tempo real detecta e acompanha objetos em movimento na cena, e para cada objeto em movimento gera um vetor de características descrevendo a movimentação e direção e título(cabeçalho, classe) e sua relação espacial com todos os objetos próximos se movendo.**
- 2. Esses vetores de características contituem a entrada para os modelos de comportamento estocásticos baseados em estados. Ambos <sup>1</sup>HMMs e <sup>2</sup>CHMMs, com diferentes estruturas dependendo da complexidade do comportamento são utilizados para classificar e perceber comportamentos.**

( Processo estocástico é uma coleção de variáveis aleatórias que, em geral, são utilizadas para estudar a evolução de fenômenos (ou sistemas) que são observados ao longo do tempo. Assim, ao invés de descrevermos o sistema através de equações determinísticas (como, equações diferenciais ordinárias), que dado uma condição inicial, conhecemos toda a evolução do sistema, vamos utilizar processos estocásticos, para o qual, dado uma condição inicial, ainda temos diversas trajetórias possíveis para a evolução do sistema. ) - fonte: <http://www.portalaaction.com.br/processo-estocastico>

“HMM é um processo duplamente estocástico, com um processo estocástico não visível, o qual não é observável (daí o nome de escondido), mas que pode ser observado através de outro processo estocástico que produz a seqüência de observações”. - Rabiner L. R



“HMM é um processo duplamente estocástico, com um processo estocástico não visível, o qual não é observável (daí o nome de escondido), mas que pode ser observado através de outro processo estocástico que produz a seqüência de observações”. - Rabiner L. R

# Segmentação e Acompanhamento



## ○ Características:



- 2D blob para cada pedestre
  - No caso do artigo um conjunto compacto de pixel que compartilham algumas propriedades visuais que não são compartilhadas pelos pixels ao redor. Essas características como cor, textura, brilho, movimento, sombra, uma combinação de tudo isso ou qualquer outra propriedade espaço-temporal destacada derivada do sinal.



# Segmentação e Acompanhamento



- Espaço Eigen para o fundo
  - Para detectar os pedestres é construído um espaço eigen que modela o fundo. Esse modelo descreve o intervalo das aparências (como variações de iluminação durante o dia, mudanças no clima etc) que foram observados.





# Segmentação e Acompanhamento



## ○ Espaço Eigen(Segmentação):

- Construção

- Formado a partir de uma amostra de imagens sobre as quais é calculado o meio  $\mu_b$  da imagem de fundo e sua matrix de covariância  $C_b$ . Essa matrix é diagonalizada por uma decomposição de valores eigen

$$L_b = \phi_b C_b \phi_b^T$$

$\phi_b$  : matriz de vetores eigen da covariância dos dados

$L_b$  : matriz diagonal correspondente dos valores eigen

- Apenas alguns vetores eigen(M) são guardados correspondendo aos maiores vetores para nos dar a matrix  $\phi_m$ . Então é formado um vetor de características dos componentes principais



$$I_i = \phi_{M^b}^T X_i$$

# Segmentação e Acompanhamento(Traking)



## • Espaço Eigen(Segmentação):

- Construção
  - Onde  $X_i = I_i + \mu_b$  é o vetor medio, normalizado da imagem





# Segmentação e Acompanhamento(Traking)



## ○ 2D blod(Acompanhamento):

- Trajetória
  - Cada blob tem sua trajetória guardada em uma memória de acompanhamento dinâmico. Cada trajetória tem um filtro de Kalman associado para prever sua posição e velocidade no próximo frame.
  - Para lidar com oclusões e manter a correspondência entre blobs cada blob também é modelado por Uma FDP(função de distribuição probabilística) gauseano em RGB(espaço de cor).
  - A FDP de Kalman e a Gauseana são combinadas.
  - Nos frames que seguem a distância de Mahalanobis é utilizada para determinar o blob que deve ser identificado como o mesmo.

# Modelos de comportamento



## ○ Problemas:

- Lidar com o peso computacional do processamento frame a frame de todos os agentes e suas interações.
- Lidar com toda essa informação através do tempo acumulada

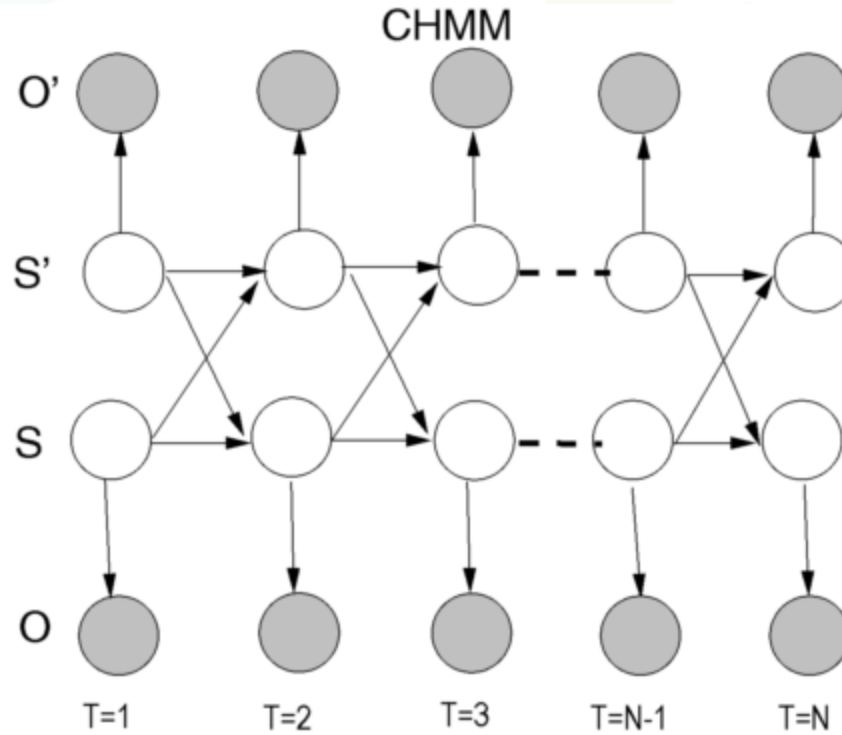


# Modelos de comportamento



- Entendendo visualmente:


- CHMM



# Modelos de comportamento



## Entendendo visualmente:




- São utilizadas duas CHMM para modelar dois processos interagindo que correspondem a um humano cada um.
- Duas pessoas podem interagir sem modificar completamente o comportamento da outra. Cada processo tem comportamento e dinâmicas próprias que podem ser influenciados.
- Correntes são casadas via matrizes de probabilidades condicionais modelando influencias de causa entre suas variáveis de estados ocultos.

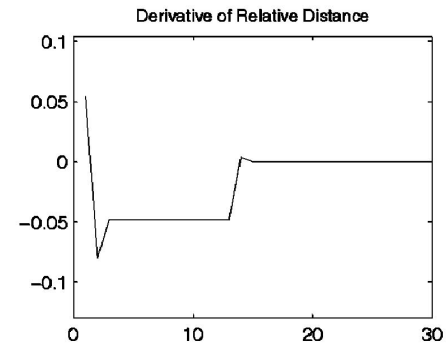

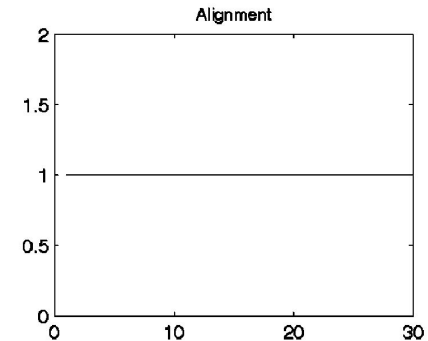
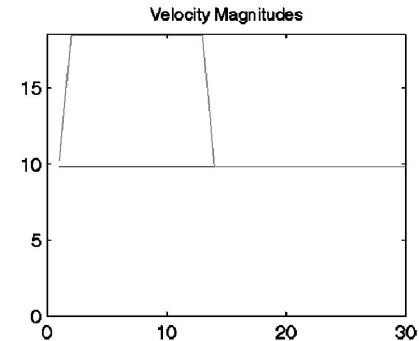
# Modelos de comportamiento



## Comportamento: Seguir



Agent trajectories for inter1

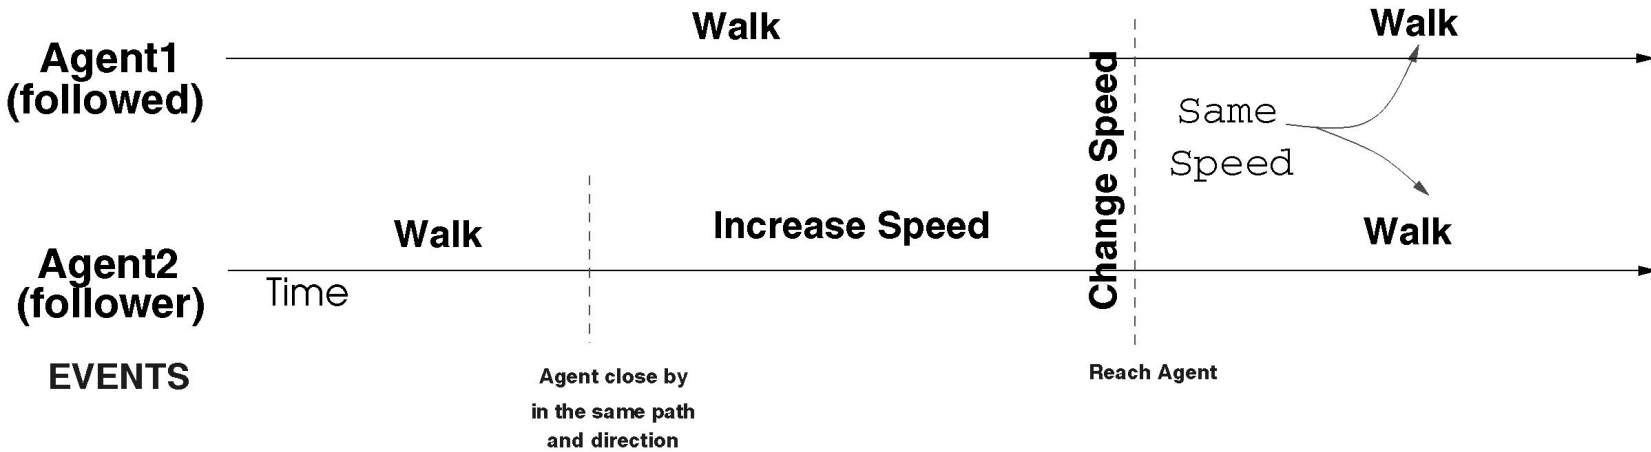


Feature Vector for inter1

# Modelos de comportamiento



## FOLLOW (inter1)








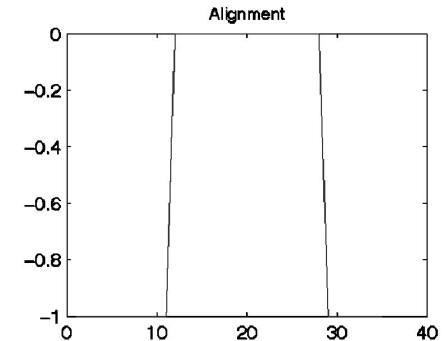
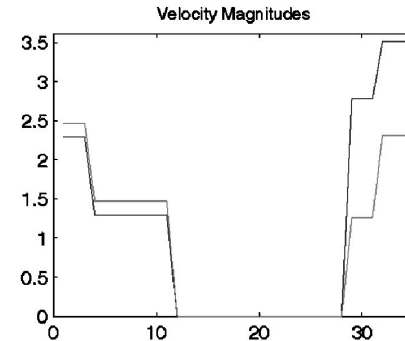
# Modelos de comportamento



- **Comportamento: Aproximar, encontrar e seguir separado**



Agent trajectories for inter2

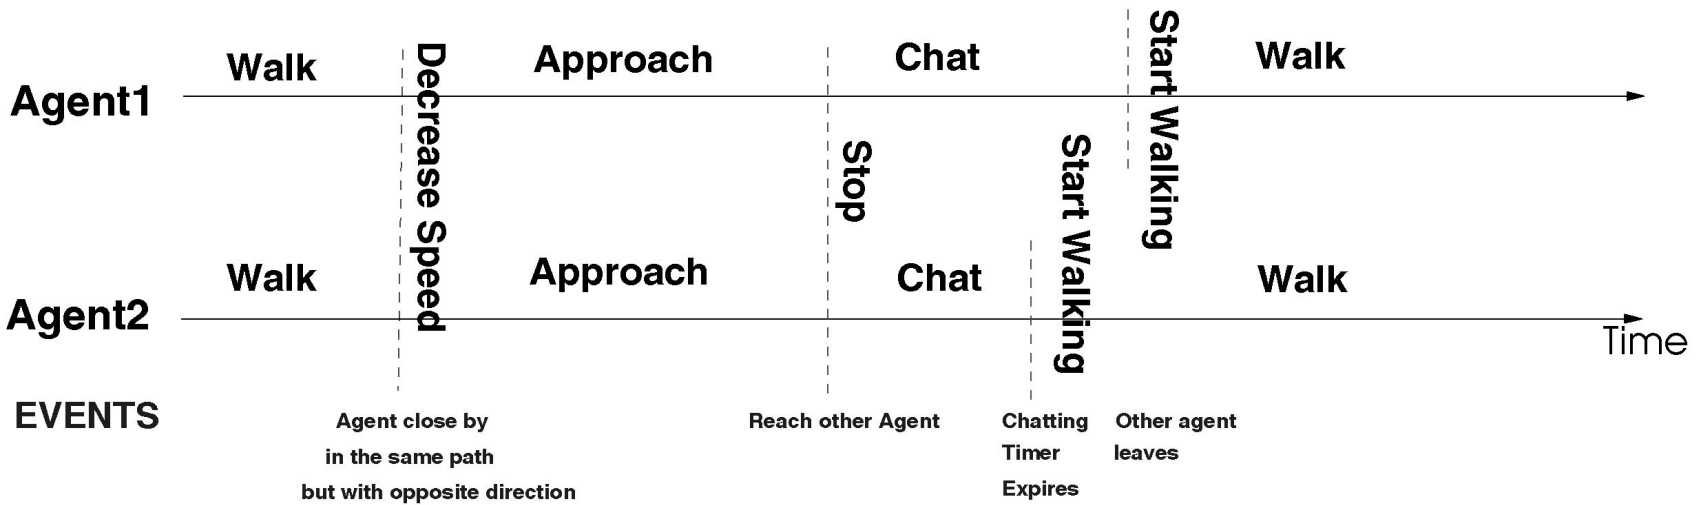


Feature Vector for inter2

# Modelos de comportamiento




## APPROACH+TALK+CONTINUE SEPARATELY (inter2)



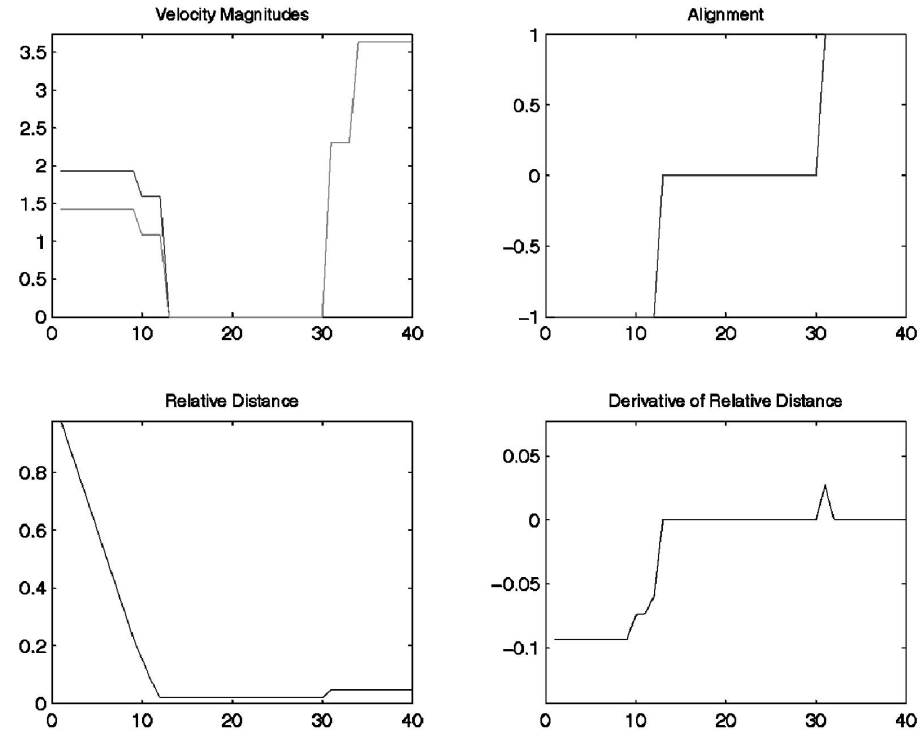
# Modelos de comportamento



- Comportamento: Aproximar, encontrar e continuar juntos



Agent trajectories for inter3

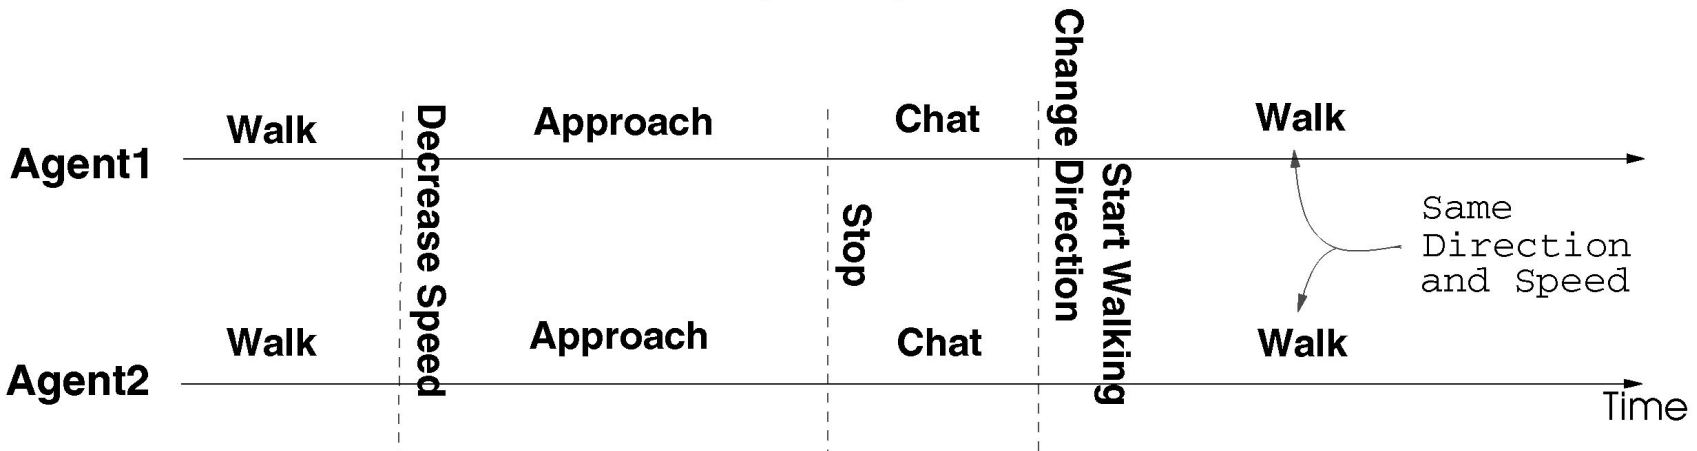


Feature Vector for inter3

# Modelos de comportamiento



## APPROACH+TALK+CONTINUE TOGETHER (inter21)



# Resultados



**TABLE 2**  
**Accuracy for Both Untuned, a Priori Models, and Site-Specific CHMMs Tested on Real Pedestrian Data**

Accuracy on real pedestrian test data (%)		
	Prior CHMMs	Posterior CHMMs
No-inter	90.9	100
Inter1	93.7	100
Inter2	100	100
Inter3	100	100

*The first entry in each column is the interaction versus no-interaction accuracy, the remaining entries are classification accuracies between the different interacting behaviors. Interactions are: “Inter1” follow, reach, and walk together; “Inter2” approach, meet, and go on; “Inter3” approach, meet, and continue together.*