

sdpa 2007



Associação
Portuguesa
Para a
Inteligência
Artificial

**SIMPÓSIO
DOUTORAL EM
INTELIGÊNCIA
ARTIFICIAL
2007**

*Cesar Analide
Paulo Novais
Pedro Henriques*

Issues and Directions for Distributed Clustering of Streaming Sensors	77
<i>Pedro Pereira Rodrigues</i> <i>João Gama, Luis Lopes</i>	
Técnicas de Inspeção de Programas para Inter-relacionar as Vistas Comportamental e Operacional	87
<i>Mario Marcelo Berón</i> <i>Pedro Rangel Henriques, Maria João Varanda, Roberto Uzal</i>	
Collaborative Networks in Smart Homes for Care of the Elderly	97
<i>Ricardo Costa</i> <i>Paulo Novais, José Neves</i>	
Visualização de Correlações Espaciais em Séries de Dados Georeferenciadas.....	103
<i>Rosa Matias</i> <i>João Paulo Moura, Paulo Martins, Fátima Rodrigues</i>	
Applying Virtual Learning Environments in a Portuguese High School Context ..	115
<i>Joaquim Silva</i> <i>Francisco Restivo</i>	
Argumentação baseada em Lógica Não-Monótona	125
<i>Emanuel Santos</i> <i>João Pavão Martins</i>	
Segmentação Bilingue com base na Marker Hypothesis	135
<i>Alberto Simões</i> <i>José João Almeida</i>	
Genetic Algorithms for Polyphonic Music Transcription.....	145
<i>Gustavo Reis</i> <i>Francisco Fernandez</i>	
Control of Affective Content in Music Production.....	155
<i>António Pedro Oliveira</i> <i>Amílcar Cardoso</i>	
Previsão de Eventos Anormais em Sistemas de Vídeo-vigilância.....	165
<i>Duarte Duque</i> <i>Henrique Santos, Paulo Cortez</i>	
A proposal for a Ubiquitous Group Decision Support System.....	175
<i>Ricardo Santos</i> <i>Carlos Ramos, José Bulas-Cruz</i>	
GridClass - A LCS System for Grid Data Mining.....	185
<i>Hélder Quintela</i> <i>Manuel Filipe Santos, Tim Kovacs</i>	

SDQA
2007

Simpósio Doutoral em Inteligência Artificial, 2007

Guimarães, Portugal

3 de Dezembro de 2007

Organização

Cesar Analide
Paulo Novais
Pedro Henriques

Comité do Programa

Alípio Jorge (FEP-UP)
Anália Lourenço (DI-UM)
António Abelha (DI-UM)
Arlindo Oliveira (INESC-IST)
Carlos Damásio (FC-UNL)
Carlos Ramos (ISEP)
Carlos Soares (FEP-UP)
Cesar Analide (DI-UM)
Ernesto Costa (FC-UC)
Fátima Rodrigues (ISEP)
Gabriel Pereira Lopes (FC-UNL)
Gaél Dias (UBI)
João Balsa (FC-UL)
José Júlio Alferes (FC-UNL)
José Machado (DI-UM)

José Maia Neves (DI-UM)
José Tomé (INESC-IST)
Luís Antunes (FC-UL)
Luís Correia (FC-UL)
Luís Moniz Pereira (FC-UNL)
Luís Paulo Reis (FEUP-UP)
Luís Rocha (Indiana University)
Manuel Filipe Santos (DSI-UM)
Orlando Belo (DI-UM)
Paulo Azevedo (DI-UM)
Paulo Novais (DI-UM)
Pedro Rangel Henriques (DI-UM)
Rui Mendes (DI-UM)
Salvador Abreu (UE)
Victor Alves (DI-UM)

Painel de Convidados

Luís Correia (FC-UL)
Carlos Soares (FEP-UP)
José João Almeida (DI-UM)
Victor Alves (DI-UM)

Orador Convidado

Luís Correia (FC-UL), "Taking a PhD in AI – empirical notes"

Previsão de Eventos Anormais em Sistemas de Vídeo-vigilância

Duarte Duque, Henrique Santos, Paulo Cortez

Universidade do Minho, Departamento de Sistemas de Informação, Campus de Azurém,
4800-058 Guimarães, Portugal
{duarteduque, hsantos, pcortez}@dsi.uminho.pt

Resumo. Este trabalho tem como propósito a detecção e previsão de comportamentos passíveis de originar uma quebra de segurança. Tais comportamentos são reconhecidos por meio da observação de padrões de actividade humana, extraídos de sequências de imagens digitalizadas adquiridas por intermédio de uma câmara de vídeo a cores, monocular e fixa. A aferição dos comportamentos é suportada pela informação resultante dos processos de detecção, classificação e seguimento de objectos em movimento, minimizando a utilização de informação de contexto na cena observada, e sem recurso a descrições de comportamentos previamente definidos. Para a detecção e previsão automática de comportamentos desenvolveu-se um novo classificador (*Dynamic Oriented Graph*) proposto no âmbito deste trabalho e que, utilizando os dados provenientes das funções de processamento e análise de imagem, permite modelar sequências temporais. O sistema, constituído pela junção das várias componentes desenvolvidas e implementado numa câmara de vídeo *inteligente*, foi testado com um conjunto de dados sintéticos.

Palavras-chave: Detecção de Comportamentos, Vídeo-vigilância.

Grau Académico a Atingir: Doutoramento.

Data de Início: Outubro de 2004.

Data Prevista para Conclusão: Janeiro de 2008

1 Introdução

Uma corrente usual na análise e reconhecimento de comportamentos em vídeo-vigilância advoga que o comportamento de um objecto pode ser descrito por uma sequência de acções atómicas (e.g. andar, correr, parar) que este executa num determinado ambiente [1, 2]. Tal abordagem requer geralmente o conhecimento do histórico de estados dos atributos de maior relevância e representatividade do objecto alvo (e.g. mãos, pés e cabeça). A aquisição de medições destes atributos pode ser difícil e em muitos casos impraticável, quando se pretendem monitorizar situações reais em ambientes não-laboratoriais.

Em instalações de vídeo-vigilância os objectos encontram-se frequentemente afastados da câmara de vídeo e a existência de vários objectos em simultâneo, movimentando-se na cena, originam fenómenos problemáticos (e.g. oclusão parcial ou total de objectos) que podem induzir erros ou falhas na detecção. Uma outra adversidade na implementação deste tipo de abordagem advém do facto de, apesar da existência de métodos bem conhecidos para a identificação de acções atómicas, o reconhecimento do início e fim de tais eventos é de extrema dificuldade. Um obstáculo suplementar consiste na procura pela descrição da correcta sequência de acções, a qual é principalmente baseada no conhecimento que o utilizador detém sobre os comportamentos de interesse.

Outra proposta para a análise de comportamento, em vez de se fixar sobre uma cadeia de acções atómicas, analisa a totalidade da sequência temporal com o intuito de assimilar e reunir padrões de actividades distintas [3]. Este género de abordagem pode ser considerada mais robusta, dado que os comportamentos são extrapolados numa perspectiva global e não por uma restritiva sequência de acções. Tal abordagem requer, no entanto, sofisticados métodos de mineração (*data mining*) para elevados volumes de dados, com o objectivo de descobrir padrões comuns a determinados tipos de comportamentos. A informação resultante deste processo é então utilizada na construção de modelos que representam tais comportamentos.

Na classificação de comportamentos é usual o recurso a informação de contexto, quer seja sobre a actividade ou sobre o ambiente monitorizado, como forma de melhorar as capacidades da técnica de classificação. Como exemplo, no âmbito do projecto ADVISOR [2] a detecção de actos de vandalismo implica a modelação tridimensional do espaço monitorizado, bem como a descrição dos eventos relevantes (efectuado por peritos de segurança através de uma linguagem de descrição especialmente concebida para o efeito).

No âmbito deste trabalho pretende-se desenvolver um classificador que reduza ao mínimo a utilização de informação de contexto. Tal opção de concepção baseia-se numa preferência pela capacidade de generalização do classificador em detrimento da precisão e detalhe da tipologia dos eventos. Num sistema de vigilância, salvo aplicações específicas, não é viável a descrição da totalidade das actividades de interesse. Em ambientes reais, o número de actividades é elevado, as sequências de acções são complexas, e alterações no ambiente implicam uma redefinição das actividades suspeitas.

Da perspectiva da segurança os comportamentos podem ser coligidos em três tipos base: comportamento **normal**, **não usual** e **anormal**. Tipicamente, numa área sob vigilância o foco de atenção recai na detecção de **comportamentos não usuais** (e.g. uma pessoa a correr no *lobby* de um hotel) e na identificação de **comportamentos anormais** (e.g. violação de uma área restrita ou uma pessoa atravessando uma via ferroviária).

Como comportamentos **normais** entendem-se aqueles que são frequentemente observados, não originando a violação de qualquer área restrita. Eventos **não usuais** são aqueles cuja frequência de acontecimento é bastante reduzida ou que a ocorrência nunca foi verificada. Quando uma acção leva à violação de uma área restrita, deve então ser classificada como um comportamento **anormal**.

Com a adopção desta abordagem, não existe necessidade de definir contextos complexos para cada cena ou actividade. Ao utilizador apenas é requerido que defina as regiões onde se aplicam restrições a determinados tipos de objectos (i.e. pessoas, grupos de pessoas, e veículos).

Com base nesta classificação simples de comportamentos, a detecção de eventos não usuais e a previsão de actividades anormais pode ser definida pelas seguintes questões: A trajectória de um objecto com propriedades específicas (como cor, área, perímetro) é reconhecida? Se é reconhecida, baseando-se no histórico da trajectória e propriedades (e.g. cor do objecto), qual é a probabilidade do objecto seguir um caminho que o levará à violação de uma área restrita?

2 O Classificador *Dynamic Oriented Graph*

Uma possível técnica para modelação de comportamentos é conseguida através do recurso a uma estrutura de nós, conectados de forma unidireccional, cada um definindo uma região no hiperespaço de atributos, para um intervalo de tempo predefinido, tendo associada uma probabilidade de geração de eventos anormais. Os dados fornecidos ao classificador incluem informação temporal e espacial acerca da trajectória do objecto, embora possam também ser examinados outros atributos, considerando características tais como a cor principal, a área ou o perímetro do objecto. Formalmente, neste trabalho propõe-se um classificador denominado de *Dynamic Oriented Graph* cujos nós são compostos por dois tipos de informação:

- **Distribuição Gaussiana Multivariável** – $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$;
- **Probabilidade de Evento Anormal** – P_{ea} .

A distribuição gaussiana $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ é representada por um vector contendo a média dos atributos dos objectos ($\boldsymbol{\mu}$) e por uma matriz de covariância ($\boldsymbol{\Sigma}$). De modo a simplificar o processo de cálculo, assume-se que não há correlação entre os diferentes atributos. A *Probabilidade de Evento Anormal* (P_{ea}) consiste na possibilidade de um objecto vir a violar uma área restrita, sabendo que este seguiu um determinado trajecto, de acordo com as relações temporais e espaciais do modelo. Por outras palavras, se um objecto percorrer um caminho semelhante a um padrão que se verificou ter conduzido a uma violação de área restrita, então a probabilidade de este objecto gerar um evento anormal é elevada. Esta probabilidade, que será utilizada posteriormente na identificação de eventos anormais, é obtida pela razão entre o número de trilhos que passaram pelo nó e que originaram a violação de uma área restrita; e o número total de trilhos que transitaram pelo mesmo nó, ou seja:

$$P_{ea} = \frac{\text{Número de trilhos com violação de área restrita}}{\text{Número total de trilhos}} \quad (1)$$

Existem algumas semelhanças entre o classificador proposto e as *Redes de Bayes*. Ambos são definidos por um grafo acíclico direccionado, em que os arcos representam influência directa de um nó em outro. Contudo, nas *Redes de Bayes* as variáveis são representadas exclusivamente pelos nós do grafo, em que cada nó indica um atributo. Tal facto já não se verifica no *DOG*, onde cada nó define uma função densidade de probabilidade que considera todos os atributos à excepção do tempo.

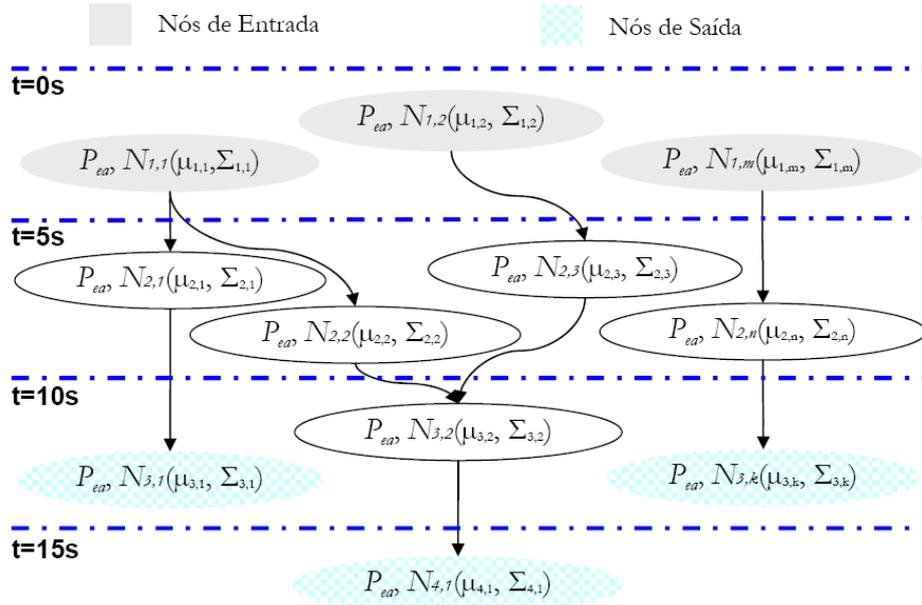


Figura 1. Exemplo da estrutura de um classificador *Dynamic Oriented Graph*.

Como se pode verificar na Figura 1, o grafo de classificação encontra-se organizado por camadas temporais de tal modo que cada novo trilho deve ser descrito por uma sequência de nós (um nó por camada), principiando num nó de entrada. Em cada camada são definidas regiões no hiperespaço dos atributos, obtidas a partir de funções densidade de probabilidade do conjunto de atributos para um determinado período de tempo. Uma outra perspectiva de uma estrutura que modela os comportamentos observados, segundo o classificador *Dynamic Oriented Graph*, pode ser descrita pela Figura 2.

O modelo *DOG* pode então ser visto como um classificador espaciotemporal enriquecido com atributos característicos dos objectos, tais como a sua área, perímetro, cor dominante, entre outros. Este classificador é construído a partir de trilhos previamente observados e classificados (apenas como eventos normais ou anormais), sendo definidos por sequências de vectores de atributos que descrevem as propriedades de um objecto a cada intervalo de tempo.

O primeiro passo na construção do classificador *DOG* consiste no sectionamento dos dados, i.e. trilhos, em secções de igual período temporal (e.g. secções de 250 imagens, considerando que a aquisição de imagens é efectuada em intervalos de tempos constantes). Seguidamente, é calculado o valor médio de cada atributo para cada uma das secções definidas pelo passo anterior.

A fragmentação dos trilhos em secções de intervalos temporais fixos, com a subsequente redução ao valor médio, tem como propósito a diminuição do volume de dados a tratar. Este procedimento pode ser encarado como a execução de uma amostragem da informação produzida pelo processo de análise de vídeo.

O *DOG* foi idealizado com a finalidade de proporcionar um modelo de classificação adaptativo, i.e. exibir *plasticidade*, permitindo a geração de novas classes bem como possibilitar a sua reorganização caso os dados assim o determinem. Contudo, esta capacidade de incorporar novos padrões pode originar *instabilidade* nas estruturas das classes, tendo como efeito a perda de significado das classes resultantes. A esta contradição dá-se o nome de *dilema plasticidade/estabilidade* [4]. O classificador proposto supera este dilema pela integração de uma variante da *Teoria da Ressonância Adaptável (ART) Gaussiana* [5] com um método de fusão das classes que partilhem uma mesma região no hiperespaço definido pelos atributos.

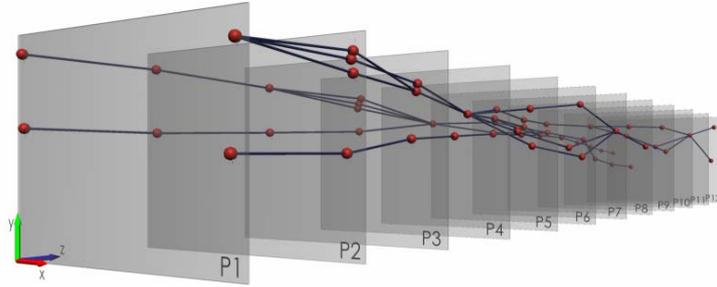


Figura 2. Representação tridimensional de um classificador *Dynamic Oriented Graph*.

2.1 Representação das Classes

Segundo a *Teoria da Ressonância Adaptável Gaussiana*, uma classe é definida através de uma distribuição gaussiana $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, apresentando um valor de média e de desvio padrão para cada dimensão. Esta informação é complementada por uma probabilidade *a priori* associada à respectiva classe, bem como pelo número de amostras que ela abarca.

Considerando M_c como sendo o número de amostras abrangidas pela classe W_c , de um total de C classes identificadas, então a probabilidade *a priori* de uma classe c , é definida por:

$$P(W_c) = \frac{M_c}{\sum_{i=1}^C M_i} \quad (2)$$

As distribuições geradas a partir da aplicação da *ART Gaussiana* têm a particularidade de facultar um ajuste aos dados bastante satisfatório quando estes não apresentam uma correlação entre atributos, i.e. quando os atributos são independentes. Quando tal não se sucede, a sua influência pode ser minimizada através de uma análise prévia da correlação entre atributos. Com efeito, nos casos em que se verifique uma elevada correlação entre duas ou mais variáveis, é possível manter características discriminantes de cada classe utilizando apenas um dos atributos correlacionados e desprezando os restantes.

2.2 Selecção e Atribuição de uma Classe a um Vector de Entrada

À luz da *Teoria da Ressonância Adaptável Gaussiana* é possível a partilha de uma mesma região do espaço por várias distribuições gaussianas. Como tal, a associação de um vector de entrada, à classe que melhor o representa, é efectuada em duas fases. Inicialmente executa-se uma selecção da classe cuja distribuição constitua a procedência mais provável da amostra. Após a selecção, verifica-se se o critério de correspondência entre a amostra e a classe é satisfeito. Em caso afirmativo prossegue-se com a actualização dos parâmetros que definem a classe. Se tal não se verificar, uma nova classe é seleccionada.

A abordagem proposta para a construção do classificador *DOG* diverge neste aspecto da *ART Gaussiana*. De modo a reduzir a complexidade deste processo, optou-se por uma solução que promove a fusão das classes cujas distribuições partilhem uma mesma região. Como resultado, cada classe define univocamente um espaço do hiperespaço delimitado pelos atributos.

Considere-se \mathbf{x} como o vector de entrada, de dimensão d , obtido pela média dos valores observados para cada atributo no período de tempo associado à camada temporal em análise. Considere-se ainda que na referida camada temporal se encontram definidas C classes identificadas por distribuições gaussianas $N_c(\boldsymbol{\mu}_c, \boldsymbol{\Sigma}_c)$, onde,

$$\boldsymbol{\Sigma}_c = \prod_{i=1}^d \sigma_{c,i}^2 \quad (3)$$

A condição para a atribuição de uma classe a um vector de entrada \mathbf{x} , é definida por:

$$\begin{cases} \text{atribuído} & , \text{ se } |x_{c,i} - \mu_{c,i}| \leq \sigma_{c,i} \quad , \exists c \in C \wedge \forall i \in d \\ \text{não atribuído} & , \text{ caso contrário} \end{cases} \quad (4)$$

2.3 Método de Aprendizagem

Sempre que para um vector de entrada seja satisfeita a condição de atribuição a uma classe, esta deve ver actualizada a sua média, matriz de correlação e contador de amostras. No entanto, nos casos em que o vector de entrada não seja associado a qualquer classe (quer seja pela inexistência de classes na referida camada temporal, ou pelo não cumprimento do critério de atribuição), então uma nova classe é gerada.

A criação de uma classe implica a constituição de uma distribuição gaussiana cuja média é definida pelo vector de entrada (i.e. $\boldsymbol{\mu}=\mathbf{x}$), e por uma matriz de covariância baseada nos valores iniciais considerados para o desvio padrão em cada atributo. Como efeito, obtém-se um espalhamento isotrópico no espaço característico ao redor da primeira amostra da classe.

A técnica aqui proposta tem como finalidade a sua utilização num sistema de vídeo-vigilância real, onde a monitorização continuada pode proporcionar um elevado número de observações. Como tal, é indispensável que o processo de contagem de amostras seja dotado de mecanismos que permitam evitar problemas de implementação relacionados com a limitação de capacidade da variável que armazena o número de observações abarcadas por cada classe (i.e. problemas de *overflow*).

Com este propósito desenvolveu-se uma técnica de contagem de amostras que possibilita não só evitar os problemas de limite de armazenamento da variável de contagem, como permite também implementar um método de “esquecimento” das classes que registem um número reduzido de observações.

Se M_c identificar a variável de contagem de amostras numa classe c , e $Mmax$ representar o valor máximo que a variável pode tomar, então quando a condição de atribuição é verificada para uma determinada classe, o seu contador de amostras é incrementado em uma unidade se o valor for inferior ao limite máximo, i.e. $M_c = M_c + 1$ se $M_c < Mmax$. Contudo, se se verificar que o contador tenha atingido o limite máximo ($M_c = Mmax$), então procede-se a uma redução, em uma unidade, nos contadores de todas as classes representadas pelo classificador, i.e. $M_n = M_n - 1$. Sempre que nesta operação um contador de amostras atingir o valor nulo ($M_n = 0$), essa classe é removida do classificador.

Após a actualização do contador de amostras, o processo de aprendizagem da classe identificada prossegue com o ajuste dos valores de média e desvio padrão para cada atributo de modo a reflectir as propriedades da nova amostra.

Para cada $i \in d$ fazer

$$\begin{aligned} \mu_{c,i} &= \begin{cases} (1-\lambda) \cdot \mu_{c,i} + \lambda \cdot x_i & , \text{ se } M_c > 1 \\ x_i & , \text{ se } M_c \leq 1 \end{cases} \\ \sigma_{c,i} &= \begin{cases} (1-\lambda) \cdot \sigma_{c,i} + \lambda \cdot |x_i - \mu_{c,i}| & , \text{ se } M_c > 1 \\ \sigma_{inicial} & , \text{ se } M_c \leq 1 \end{cases} \end{aligned} \quad (5)$$

com, $0 \leq \lambda \leq 1$.

2.4 Fusão Entre Classes

Depois de concluído o processo de actualização das classes numa camada temporal, procede-se à verificação da existência de sobreposições entre as diversas distribuições representadas pelas classes aí definidas. Em caso afirmativo realiza-se uma fusão entre classes, duas a duas, de acordo com o especificado em (6).

Se, $M_{c1} + M_{c2} < Mmax$, então

$$M_c = M_{c1} + M_{c2}$$

Caso contrário,

$$M_c = \frac{M_{c1} + M_{c2}}{2} \quad (6)$$

Para cada $i \in d$ fazer

$$\begin{aligned} \mu_{c,i} &= \frac{M_{c1}}{M_c} \cdot \mu_{c1,i} + \frac{M_{c2}}{M_c} \cdot \mu_{c2,i} \\ \sigma_{c,i} &= \frac{1}{2} \cdot \left[MAX(\mu_{c1,i} + \sigma_{c1,i}, \mu_{c2,i} + \sigma_{c2,i}) - MIN(\mu_{c1,i} - \sigma_{c1,i}, \mu_{c2,i} - \sigma_{c2,i}) \right] \end{aligned}$$

2.5 Mecanismo de Classificação de Comportamentos

Quando um novo objecto entra em cena, realiza-se o processo de associação do vector de entrada às classes pertencentes à primeira camada temporal. Se não for satisfeita a condição de atribuição da amostra a um dos nós da camada inicial, considera-se que se está na presença de um **evento não usual**. Caso contrário, se a amostra é atribuída a um dos nós, procede-se à avaliação da *Probabilidade de Evento Anormal* (P_{ea}). Nos casos em que o valor da P_{ea} para o nó seleccionado seja superior a um limite predefinido, denominado por *Limite de Alarme* (A_t), então o classificador assinala a ocorrência de um **evento anormal**. No entanto, sempre que P_{ea} apresentar um valor igual ou inferior a A_t , avança-se no próximo espaço de tempo com o processo de associação, recorrendo aos “nós filhos” definidos na camada temporal seguinte.

Com a variação do parâmetro de *Limite de Alarme* é possível ajustar o classificador de modo a permitir a previsão da ocorrência de eventos de violação de espaços restritos. Com efeito, baixos valores de A_t possibilitam uma elevada antecipação na sinalização de eventos anormais. Por outro lado, quando A_t assume valores próximos do máximo, o classificador tende a perder a capacidade de previsão, realizando apenas a detecção de eventos de quebra de segurança.

A escolha do valor do parâmetro A_t deve ter em consideração as necessidades específicas de cada aplicação. Se por um lado em alguns ambientes se pretende sinalizar com enorme precocidade a possibilidade de violação de um espaço restrito, tolerando eventuais falsas detecções do classificador, em outros casos é dada preferência a uma reduzida taxa de erro em detrimento do nível de antecipação na detecção de eventos. Através da análise de risco do local sob vigilância é possível tomar uma decisão sobre o valor a atribuir ao *Limite de Alarme*. Como tal, devem-se ponderar diversos factores como: a vulnerabilidade do local, o tipo e probabilidade de ocorrência de ameaças, bem como o impacto que estas possam causar. Cabe ao utilizador adoptar pela estratégia mais adequada a cada situação.

3 Teste dos Classificadores Sobre Dados Sintéticos

Para a análise do classificador *DOG* adoptou-se um esquema de *validação cruzada* do tipo *10-fold cross validation* [6]. Assim, o classificador foi avaliado utilizando a cada etapa do processo 9/10 do conjunto de dados para a aprendizagem dinâmica do modelo e os restantes 1/10 para teste do classificador com inibição da capacidade de adaptação. De modo a aumentar o grau de confiança dos resultados da avaliação, realizaram-se 30 diferentes execuções de *10-fold cross validation* para cada classificador. Como tal, o teste do classificador implica a simulação de 30 processos de validação, o que perfaz uma soma total de 3 milhões de trilhos a processar, i.e. 1000 trilhos por 30 execuções de *validação cruzada*, onde são testados 100 valores distintos para o parâmetro de *Limite de Alarme* (A_t). O teste foi executado num computador baseado em processador de 32 bits a 3.0GHz, com 512MB de memória RAM, e operando um sistema *GNU/Linux*.

Para além do tempo consumido pelo classificador, pretende-se ainda aferir os seus níveis de eficácia na previsão de comportamentos. Como tal, foram calculadas a curva *ROC* [7] e a curva de *Taxa de Antecipação*. A curva *ROC* foi obtida pela construção de uma *Matriz de Confusão* para cada valor de *Limite de Alarme* (A_t), com A_t adoptando valores compreendidos entre [0%, 100%], fraccionado em intervalos de 1%. A *Taxa de Antecipação* é obtida pelo cálculo da razão entre a distância de antecipação (i.e. distância que vai desde o ponto onde foi efectuada a previsão de evento anormal até ao ponto onde ocorre a violação efectiva de um espaço restrito) e a distância total desde o início do trilho até à sua entrada numa área restrita. A *Taxa de Antecipação* é calculada para diferentes valores de A_t , de modo similar ao que acontece com a curva *ROC*.

Para cada processo de *validação cruzada*, efectuou-se a medição do tempo necessário à sua execução, bem como do número de *Verdadeiros Positivos*, *Falsos Positivos*, *Verdadeiros Negativos* e *Falsos Negativos*. Como os dados recolhidos pela execução das 30 operações de *validação cruzada* constituem uma amostra relativamente pequena, não se justifica assumir uma *Distribuição Normal* das medições realizadas [8]. Em substituição, considera-se uma *Distribuição t-student* para o cálculo dos intervalos de confiança dos *Verdadeiros* e *Falsos Positivos*.

A realização total do teste para o classificador *DOG* requereu somente 1 minuto e 29 segundos. Na Figura 3(a) é apresentada a curva *ROC* para o classificador *DOG* onde se exhibe, para cada valor de A_t , as variações esperadas para um intervalo de confiança de 95%. Uma outra métrica de avaliação do desempenho de classificadores utilizada neste estudo foi a *AUC* (do inglês: *Area Under the Curve*). Com efeito, nos testes efectuados, observou-se um valor de *AUC* na ordem dos 86% para o classificador proposto.

Na Figura 3(b) é possível observar, para o domínio de valores possíveis de A_t , o comportamento do classificador proposto. Como se pode verificar, a *Taxa de Verdadeiros Positivos* decai à medida que A_t aumenta. Constata-se ainda que a *Taxa de Antecipação* diminui para valores mais elevados do *Limite de Alarme*. Suportando-se na informação fornecida pela Figura 3(b), é facilitada a tomada de decisão em relação ao valor ideal para o parâmetro de *Limite de Alarme*.

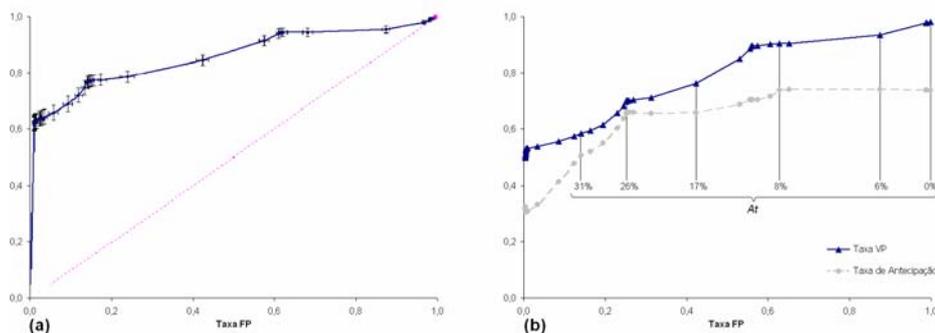


Figura 3. (a) Curva *ROC* do classificador, (b) Curva *ROC* e *Taxa de Antecipação*.

6 Conclusões

Neste artigo apresentou-se uma nova abordagem para a previsão e detecção automática de comportamentos anormais em vídeo-vigilância. Como resultado, propôs-se um classificador, denominado por *Dynamic Oriented Graph*, que permite modelar de modo satisfatório os comportamentos dos objectos observados por uma câmara de vídeo. Trata-se de um classificador cuja aprendizagem é realizada de forma não-supervisionada e que permite uma adaptação dos modelos ao longo do tempo.

A escolha do *Limite de Alarme* deve ter em consideração a combinação da informação da curva *ROC* com a curva da *Taxa de Antecipação*, permitindo assim definir um valor óptimo, baseado no compromisso entre a *Taxa de Falsos Positivos*, *Taxa de Verdadeiros Positivos* e nível de antecipação requerido.

Referencias

1. Dempster A.P., Laird N.M., Rubin D.B.: Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society, Series B*, Vol. 39. (1977) 1-38.
2. Naylor M.: ADVISOR project (2006), URL: <http://www-sop.inria.fr/orion/ADVISOR>
3. Mecocci A., Pannozzo M., Fumarola A.: Automatic detection of anomalous behavioural events for advanced real-time video surveillance. *Proceedings of the International Symposium on Computational Intelligence for Measurement Systems and Applications*. (2003) 187-192.
4. Duda R.O., Hart P.E., Stork D.G.: *Pattern Classification*, John Wiley & Sons. (2001).
5. Williamson J.R.: Gaussian ARTMAP: a neural network for fast incremental learning of noisy multidimensional maps. *Neural Networks*, Elsevier Science, Vol. 9 (5). (1996) 881-897.
6. Kohavi R.: A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence*. (1995) 1137-1143.
7. Fawcett T.: ROC graphs: notes and practical considerations for data mining researchers. Tech report HPL-2003-4, HP Laboratories. Palo Alto, USA, (2003).
8. Flexer A.: Statistical evaluation of neural network experiments: minimum requirements and current practice. *Proceedings of the 13th European Meeting on Cybernetics and Systems Research*. (1996) 1005-1008.