

UNIVERSIDADE FEDERAL DO AMAZONAS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE APOIO À PESQUISA
PROGRAMA INSTITUCIONAL DE INICIAÇÃO CIENTÍFICA

RECONHECIMENTO DE PADRÕES EM SINAIS DE VÍDEOS
UTILIZANDO DETECTORES POR PRODUTO INTERNO

Bolsista: Luciana de Aguiar Sena

MANAUS

2015

UNIVERSIDADE FEDERAL DO AMAZONAS
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DEPARTAMENTO DE APOIO À PESQUISA
PROGRAMA INSTITUCIONAL DE INICIAÇÃO CIENTÍFICA

RELATÓRIO FINAL
PIB-E/0129/2014
RECONHECIMENTO DE PADRÕES EM SINAIS DE VÍDEOS
UTILIZANDO DETECTORES POR PRODUTO INTERNO

Bolsista: Luciana de Aguiar Sena
Orientador: D.Sc. Waldir Sabino da Silva Júnior

MANAUS
2015

RESUMO

Este trabalho de pesquisa tem como objetivo o desenvolvimento de um mecanismo denominado Detector por Produto Interno, o qual é um método de classificação de padrões que pertence à categoria de detectores baseados em filtros de correlação, para reconhecimento de padrões. Tal método pertence a uma subárea denominada Reconhecimento de Padrões por Correlação, onde a detecção e/ou reconhecimento de padrões é feito utilizando a correlação entre o padrão que se deseja detectar e/ou reconhecer e um padrão candidato. Um ponto fundamental na pesquisa é a investigação do desempenho destes classificadores frente à plataformas de hardware. A meta principal é incrementar a velocidade do detector para aplicações que utilizam processamento de vídeo. Tal desempenho será avaliado no contexto de detecção de pontos fiduciais (pontos salientes em faces humanas). Para alcançar os objetivos deste trabalho, foi seguido e está sendo seguido uma série de etapas. Primeiramente, foi realizado uma revisão bibliográfica de todo o assunto necessário para o desenvolvimento dos detectores; logo a seguir foi realizado alguns exemplos práticos e posteriormente, os detectores serão desenvolvidos, assim como as análises.

Palavras-chave: Detector por Produto Interno; Reconhecimento de Padrões por Correlação.

SUMÁRIO

1	INTRODUÇÃO	5
2	REVISÃO BIBLIOGRÁFICA	6
2.1	Sinais e Sistemas	6
2.2	Reconhecimento de Padrões	6
2.3	Sistema de Classificação	7
3	MÉTODOS UTILIZADOS	8
4	RESULTADOS E DISCUSSÕES	9
4.1	Fase de treinamento do método DPI	9
4.2	Fase de teste do método DPI	10
4.3	Fase de treinamento do método DPI-ACP	10
4.4	Fase de teste do método DPI-PCA	11
5	APÊNDICE A - CRONOGRAMA EXECUTADO	13

1 INTRODUÇÃO

Nas últimas décadas, houve um avanço grandioso da tecnologia digital transformando o mundo. A TV Digital, telefonia celular, Internet e multimídia já fazem parte da nossa realidade. Naturalmente, é necessário que haja um tratamento de tais informações que são transmitidas. Dessa forma, o Processamento Digital de Sinais se preocupa com análise matemática e prática do tratamento da informação como compreendida pelos processadores.

Recentemente, as pesquisas tem se direcionado para a utilização de processamento de sinais para o Reconhecimento de Padrões, o qual é uma área de grande abrangência, sendo aplicável em diversos campos de pesquisa. Dentre suas aplicações de grande relevância é possível citar os sistemas de detecção e reconhecimento de faces humanas.

A subárea denominada Reconhecimento de Padrões por Correlação (RPC) foi originada a partir do interesse crescente da comunidade científica na detecção e/ou reconhecimento de padrões através de filtragem. Os métodos desenvolvidos utilizam como medida de similaridade a correlação entre o padrão o qual desejamos detectar e/ou reconhecer e um padrão candidato.

O Detector por Produto Interno é um representante que utiliza técnicas de filtragem por correlação e esses detectores podem ser projetados considerando padrões de interesse e os que não são de interesse proporcionando flexibilidade em seu projeto.

Este trabalho propõe a criação de um Detector por Produto Interno e a avaliação de seu desempenho utilizando uma plataforma de hardware. A principal meta é incrementar a velocidade do detector para aplicações que utilizam processamento de vídeo. O desempenho será avaliado no contexto de um problema de detecção de pontos salientes em faces humanas denominados por pontos fiduciais, que vêm sendo utilizados de forma crescente em sistemas de visão computacional.

Este trabalho também apresenta uma certa complexidade e com isso trouxe algumas dificuldades, uma vez que muitos dos assuntos abordados neste projeto não são estudados durante a graduação e tem um conteúdo bastante extenso englobando vários conceitos que são vistos mais para o final da mesma. Muitos dos conceitos que serão vistos neste trabalho, como o Reconhecimento de Padrões por Correlação e Análise de Componentes Principais, são conceitos avançados que são poucos discutidos durante a graduação e vistos com mais frequência na área de Processamento Digital de Sinais em um mestrado ou doutorado.

2 REVISÃO BIBLIOGRÁFICA

2.1 Sinais e Sistemas

De acordo com [?], um *signal* é formalmente definido como uma função de uma ou mais variáveis, a qual veicula informações sobre a natureza de um fenômeno físico. Os sinais podem ter diversas classificações, como por exemplo, podem ser classificados em sinais de tempo contínuo ou tempo discreto. Um sinal de tempo contínuo pode ser definido como um sinal que é definido para todo um tempo t . Já um sinal de tempo discreto é definido apenas em instantes isolados de tempo.

Dessa forma, os sinais podem ser processados por *sistemas*, onde tais sinais podem ser modificados ou manipulados para que novos sinais sejam produzidos. De acordo com [?], um sistema é uma entidade que processa um conjunto de sinais (entradas) resultando em um outro conjunto de sinais (saídas).

Da mesma forma que os sinais, os sistemas também possuem certas classificações. A *invariância no tempo* e *linearidade* são umas das mais relevantes para este projeto. Um sistema é dito invariante no tempo se suas características não se modificam com o tempo. Ele deverá reagir de maneira idêntica no tempo, não importando quando o sinal de entrada seja aplicado [?]. Já a linearidade baseia-se na premissa de que a saída de um sistema tem que ser proporcional a sua entrada.

Para definir de uma forma completa o comportamento de *Sistemas Lineares e Invariantes no Tempo*, é necessário observar a sua resposta ao impulso. Esta pode ser interpretada como um comportamento do sistema em resposta a uma entrada de amplitude alta e duração bastante curta. Assim, o procedimento para determinar a saída desse sistema a partir da entrada e a resposta ao impulso é denominado *convolução*.

Em sinais de tempo contínuo, a saída é uma integral de convolução:

$$y(t) = h(t) * x(t) = \int_{-\infty}^{+\infty} h(t - \tau) \cdot x(\tau) \cdot d\tau \quad (1)$$

Em sinais de tempo discreto, a saída é uma soma de convolução:

$$y[n] = h[n] * x[n] = \sum_{-\infty}^{+\infty} h[n - k] \cdot x[k] \quad (2)$$

2.2 Reconhecimento de Padrões

Na área de Reconhecimento de Padrões, *padrão* pode significar uma entidade que pode ser dado um nome. Dessa forma, um sinal de voz ou um rosto humano são exemplos de padrões. O termo *vetor de características* é usado para se referir ao conjunto de variáveis ordenadas utilizadas para representar o padrão, sendo geralmente suas medidas ou observações

[?].

Posteriormente, é necessário atribuir tal padrão a um conjunto de *classes*. A decisão por uma classe ou outra é realizada através de um *classificador*.

2.3 Sistema de Classificação

Um sistema de classificação pode ser dividido em duas fases: **fase de operação (teste)** e **fase de aprendizagem (treino)**.

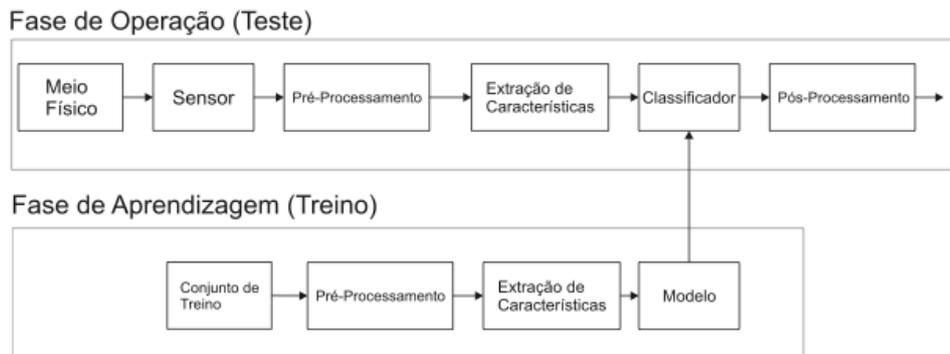


Figura 1: Sistema de Classificação

A primeira e segunda parte da fase de operação consiste em extrair informações relevantes do padrão. Logo em seguida, é feito um pré-processamento, como filtragem, correção de iluminação, remoção de ruído etc. A seguir é feita a extração de características mais importantes. Então o classificador é utilizado para categorizar esse padrão em alguma classe e por fim, é possível realizar algum pós-processamento.

Na fase de aprendizagem temos um conjunto de padrões que serão utilizado para o treinamento do modelo. As etapas de pré-processamento e extração de características são iguais as da fase de operação. Em seguida, utilizando algum algoritmo apropriado, é possível treinar algum modelo de classificação que será utilizado para obter o classificador.

3 MÉTODOS UTILIZADOS

Visando alcançar os objetivos deste trabalho, uma série de etapas está sendo seguida. De acordo com a proposta original, esta pesquisa pode ser dividida em determinadas etapas. Primeiramente, foi necessário uma revisão bibliográfica sobre o método por Detectores por Produto Interno e toda suas técnicas, incluindo um estudo sobre Análise de Componentes Principais.

Posteriormente, os Detectores por Produto Interno serão projetados e os algoritmos embarcados na plataforma de hardware Raspberry Pi para que seus desempenhos sejam analisados.

Para a validação do desempenho da plataforma será adotada a seguinte metodologia: alguns algoritmos elementares (filtragem, por exemplo) serão implementados e seus resultados serão comparados com resultados preliminares obtidos em simuladores como os que utilizam a biblioteca OpenCV e o Matlab.

O material que será utilizado será uma base de dados de faces humanas e duas sequências de vídeo. A base de dados de faces humanas é denominada de BioID e possui um total de 1521 imagens contendo faces humanas frontais em nível de cinza de 23 indivíduos diferentes. Já as duas sequências de vídeo serão geradas após o início dos testes dos detectores.

4 RESULTADOS E DISCUSSÕES

Os resultados do sistema completo ainda não foram obtidos, porém resultados parciais importantes foram atingidos. Dentre estes podemos citar: o projeto dos detectores por produto interno, entendimento da teoria matemática envolvida, completo entendimento da importância da utilização de ao menos duas bases de dados representativas para colhemos o desempenho do sistema, além da simulação de exemplos para compreensão do projeto dos detectores. Alguns desses resultados parciais serão apresentados a seguir.

No início da pesquisa, já havia um conhecimento prévio sobre a área de Sinais e Sistemas e Processamento Digital de Sinais, uma vez que as duas tem grande relação entre si. Como foi observado, o conhecimento obtido desse estudo prévio foi necessário para um maior entendimento sobre o comportamento de sinais e suas operações matemáticas (convolução, por exemplo), as quais serão bastante utilizadas para o desenvolvimento do projeto.

4.1 Fase de treinamento do método DPI

Assim como foi apresentado na subseção 2.3, um sistema de classificação é dividido em duas fases: fase de treinamento e teste. A fase de treinamento segue o especificado na Figura 1: os procedimentos para pré-processamento das imagens segue o descrito na subseção 2.3. Na fase de aprendizado, utiliza-se o conjunto de treinamento correspondente a 6/7 do total de imagens da base de dados.

Como o DPI proporciona uma flexibilidade na criação de classes, consideram-se 3 classes: A_1 , como classe de positivos formada por blocos com centros em pontos fiduciais e A_2 e B como classe de negativos. Dentre estas duas, A_2 será formada por blocos vizinhos aos blocos que pertencem à A_1 e B por outros blocos. A seguir, é acrescentado uma dimensão extra aos vetores de treinamento para que eles tenham a mesma norma. Assim, a configuração em cascata de classificadores DPI é formada por estágios, onde cada estágio é projetado utilizando os positivos do estágio anterior e cada detector será projetado utilizando as equações:

$$h_{A_n} = \left\{ p(B) \frac{1}{r} \sum_{j=1}^r b_j b_j^t + \sum_{j=1}^n p_j \frac{1}{L_j} \sum_{k=1}^{L_j} a_{jk} a_{jk}^t \right\}^{-1} \left\{ p_i \frac{1}{L_i} \sum_{k=1}^{L_i} a_{ik} \right\} \quad (3)$$

$$h_A = \left\{ p(B) R_B + \sum_{j=1}^n p_j R_{A_j} \right\}^{-1} \left\{ \sum_{i=1}^m p_i \mu_{A_i} \right\} \quad (4)$$

O produto interno $h^{*t} B_z = d_{B_z}$ é utilizado em cada estágio para o treinamento do classificador Gentle AdaBoost. A cascata formada por estágios AdaBoost e vetores \mathbf{h} representam a saída do diagrama em blocos apresentado a seguir [?].

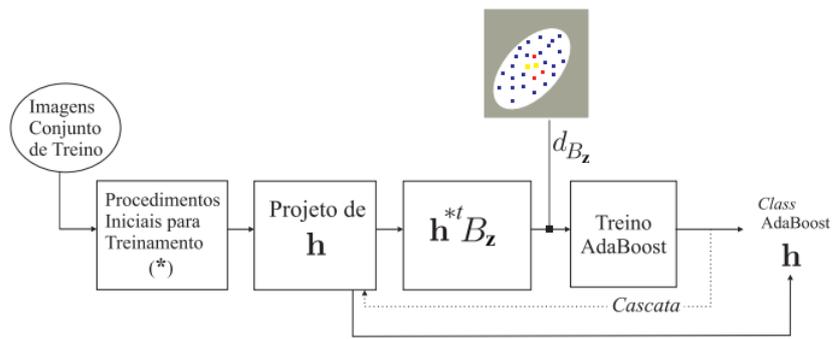


Figura 2: Diagrama em blocos para fase de treinamento do método DPI. Fonte: [?].

4.2 Fase de teste do método DPI

O conjunto de teste é composto por 1/7 do total de imagens da base de dados e será a mesma especificação para cada teste. Primeiramente, é realizado os procedimentos iniciais para o teste e logo após as imagens são processadas por uma janela deslizante B_z . A seguir, é utilizado os detectores h_{ϕ_i} obtidos no treinamento para realizar o produto interno com B_z subtraído do vetor médio. Assim, cada bloco B_z terá um vetor associado d_{B_z} . Por último, é realizada a fase de pós-processamento.

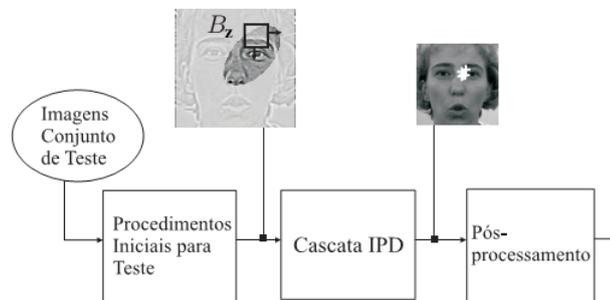


Figura 3: Diagrama em blocos para fase de teste do método DPI. Fonte: [?].

4.3 Fase de treinamento do método DPI-ACP

Assim como no método anterior, a fase de treinamento do método do Detector por Produto Interno utilizando Análise por Componentes Principais segue o especificado na Figura 1: os procedimentos para pré-processamento das imagens segue o descrito na subseção 2.3. O diagrama em blocos é apresentado a seguir:

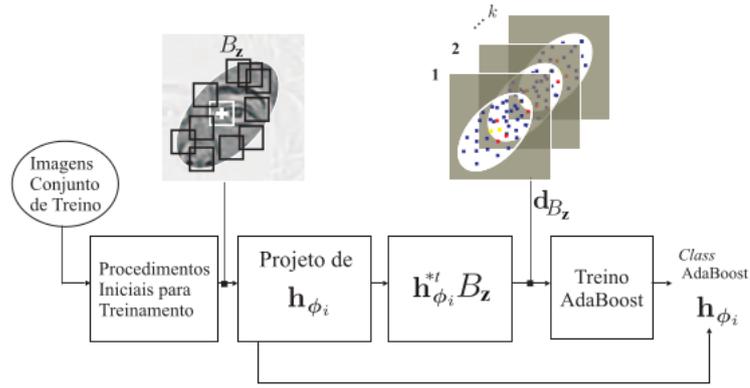


Figura 4: Diagrama em blocos para fase de treinamento do método DPI-PCA. Fonte: [?].

Após os procedimentos iniciais, os detectores h_{ϕ_i} onde $i = 1 \dots k$ serão projetados para cada uma das componentes principais com maior variância, seguindo a equação:

$$h_{\phi_i} = \{p_1 \phi_i(\phi_i)^{*t} + p_2 \frac{1}{(2L+1)^2 - 1} \sum_{n=-L}^L \sum_{m=-L}^L \phi_i^{(n,m)}(\phi_i^{(n,m)})^{*t} + p(B) \frac{1}{N-1} \sum_{j=1}^N \phi_j(\phi_j)^{*t}\}^{-1} p_1 \phi_i. \quad (5)$$

Cada bloco que pertence à classe de positivos e negativos, o qual será subtraído do bloco médio da classe de positivos, será processado utilizando a equação $h_{\phi_i}^{*t} B_z$. Assim, cada bloco B_z terá um vetor associado d_{B_z} . Estes vetores serão utilizados para treinamento do classificador Gentle AdaBoost, de uma forma que possa ser possível obter a superfície de decisão. Os vetores h_{ϕ_i} e o classificador AdaBoost são a saída do diagrama em blocos.

4.4 Fase de teste do método DPI-PCA

Da mesma forma como o método anterior, os procedimentos iniciais e pós-processamento para teste são os mesmos. As imagens também são processadas por uma janela deslizante B_z . Em seguida, é adicionada a dimensão extra em B_z e subtraído pelo vetor médio. Assim como anteriormente, cada bloco B_z tem um vetor correspondente b_z . Logo após, cada vetor é classificado pela cascata de classificadores DPI obtidos no treinamento. Por último, é realizada a etapa de pós-processamento.

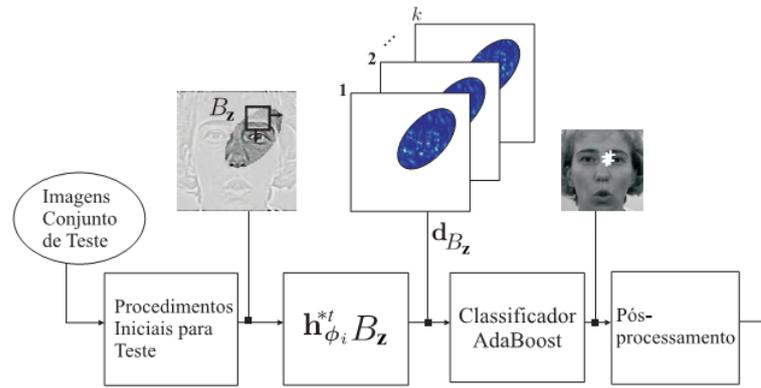


Figura 5: Diagrama em blocos para fase de teste do método DPI-PCA. Fonte: [?].

5 APÊNDICE A - CRONOGRAMA EXECUTADO

Devido à complexidade do tema, uma vez que muitos dos assuntos abordados neste projeto não são estudados durante a graduação e tem um conteúdo bastante extenso englobando vários conceitos que são vistos mais para o final da mesma, houve um certo atraso quanto às atividades que deveriam ser realizadas. Entretanto, como o mesmo foi cancelado, as tarefas não executadas serão realizadas durante o Trabalho de Conclusão de Curso e posteriormente, num possível tema para o mestrado. O cronograma apresentado a seguir está de acordo com o que foi realizado até o momento.

Atividade	Realizado
Implementar o método por Detectores por Produto Interno.	X
Implementar o método por Detectores por Produto Interno utilizando Análise de Componentes Principais.	X
Realizar comparações com métodos similares.	
Preparar plataformas de hardware para embarcar os algoritmos dos detectores.	X
Embarcar os algoritmos dos detectores por Detectores por Produto Interno nas plataformas de hardware.	
Embarcar algoritmos de detectores similares nas plataformas de hardware.	
Realizar comparações de desempenho entre os detectores por Detectores por Produto Interno e os detectores por métodos similares.	