

Classificação de Imagens Palsar para mapeamento da mesorregião do Baixo Amazonas

Michelle de Oliveira Parreira¹, Luciano Vieira Dutra²

¹Programa Doutorado em Computação Aplicada – CAP
Instituto Nacional de Pesquisas Espaciais – INPE

²Divisão de Processamento de Imagens - DPI
Instituto Nacional de Pesquisas Espaciais – INPE

{parreira.michelle, lvdutra}@gmail.com.br

***Abstract.** This article presents a remote sensing study of SAR PALSAR images in the middle region of the lower Amazonas. These images show improvements in comparison to optical data when applied to tropical regions that have high probability of clouds occurrence. The objective was to achieve textures bands with appropriate windows sizes to find patterns which can help to identify future cultures by remote sensing in the explored region. The classifications through Maximum Likelihood and Support Vector Machines allowed identify which are the best classes and statistical measures to discriminate the area.*

***Resumo.** Este artigo apresenta um estudo de sensoriamento remoto, de imagens PALSAR, em uma área da mesorregião do Baixo Amazonas. Estas imagens possuem vantagens em relação aos dados ópticos na sua utilização em regiões tropicais, por estas áreas apresentarem alta probabilidade de ocorrência de nuvens. O objetivo foi encontrar bandas de texturas com tamanhos de janelas adequados para encontrar padrões que possam auxiliar na identificação de futuras culturas por sensoriamento remoto da região explorada. As classificações por Máxima Verossimilhança e Máquinas de Vetores Suporte permitiram identificar quais as melhores classes e quais medidas estatísticas mais adequadas para discriminação da área.*

Palavras-chave: Sensoriamento Remoto, Imagens de Radar, Texturas, Classificação.

1. Introdução

O monitoramento ambiental vem ganhando grande expansão diante das disponibilidades das imagens de satélites para pesquisa e os estudos nas aplicações de sensores ópticos e microondas. Apesar dos sensores ópticos possuírem facilidade de interpretação, estes sensores apresentam vulnerabilidade na visibilidade atmosférica, desta maneira sensores microondas vêm ganhando maiores aplicações por possuírem independência das condições atmosféricas e maior poder de penetração da cobertura vegetal da região (HESS et. al., 1990). Estes sensores microondas são imageadores ativos, denominados radares de abertura sintética (SAR).

O objetivo do trabalho é encontrar bandas de texturas com tamanhos de janelas adequados para encontrar padrões que possam auxiliar na identificação de futuras culturas por sensoriamento remoto da região explorada.

2. Materiais e Métodos

A região da Floresta Nacional de Tapajós (FLONA) foi escolhida como área de estudo por apresentar diversos trabalhos realizados pelo INPE, bem como disponibilidade de imagens complexas SAR do radar ALOS/PALSAR e informações de trabalhos realizados em campos sob diferentes tipos de classes de ocupação do solo, representadas por: florestas primárias, florestas em diversas fases de regeneração, agricultura e pastagem.

FLONA abrange uma área aproximada de 600 mil hectares, localizados em terras de quatro municípios: Aveiro, Belterra, Rurópolis e Placas, no oeste do estado brasileiro do Pará (SEMA, 2011). O calendário agrícola começa em dezembro, no início da estação chuvosa, com uma ou duas atividades de plantio durante o ano, sendo as colheitas realizadas, respectivamente, em março/abril e julho/agosto.

As classes descritas na Tabela 1 foram definidas a partir de trabalhos de campo realizados em datas compatíveis com as aquisições das imagens (SILVA, 2011). Deve-se ressaltar que a Floresta degradada (FD), a Regeneração Antiga (RA) e Regeneração intermediária (RInt) foram agrupadas em uma única classe, totalizando oito classes de uso e cobertura da terra.

Tabela 1. Descrição das Classes Utilizadas. Fonte: Silva (2011).

Classes Utilizadas	Descrição	#Pixel Amostras de Treinamento	#Pixel Amostras de Testes	60 Amostras de Treinamento	Cor
Floresta Primária – FP	Floresta intacta, que não foi modificada pela atividade humana	13858	7258	11	
Floresta Degradada – FD	Florestas primárias que sofreram atividades de fogo	5480	2846	14	
Regeneração Antiga – RA	Florestas Secundárias com mais de 20 anos de reflorestamento				
Regeneração Intermediária – RInt	Florestas Secundárias de 8 a 20 anos de reflorestamento				
Regeneração Inicial – RI	Florestas secundárias com menos de 8 anos de reflorestamento	1623	546	10	
Pasto Limpo – PL	Terras usadas para pastagens com baixa presença de árvores, arbustos e espécies invasoras	510	292	12	
Pasto Sujo – PS	Terras usadas para pastagem com presença de árvores, arbustos e espécies invasoras	1252	495	2	
Agricultura Pousio - AP	Áreas agrícolas em pousio após colheita	1049	450	5	
Soja 1 – S1 – Soja_100	Soja pronta para colheita (após 100 dias da sementeira, aproximadamente)	562	306	5	
Soja 2 – S2 – Soja_40	Soja com aproximadamente 40 dias da sementeira	142	68	1	

Os dados utilizados consistem de duas imagens em amplitude multipolarizadas (HH e HV) do sensor ALOS/PALSAR, modo *Fine Beam Dual* (FBD), nível de processamento 1.5, de 21 de junho de 2010. Após captura da imagem da área de estudo pelo radar ALOS/PALSAR, a imagem original foi tratada pela etapa de Pré-Processamento. Foram realizadas correções geométricas, através de registro imagem-

imagem, utilizando como referência uma imagem TM de 2009 que estava em banco de dados e devidamente registrada, além da aplicação de Filtro Lee 5x5.

Posteriormente, foram extraídas duas bandas adicionais de HH e HV da imagem original em diferentes tamanhos de janelas, que são: Segundo Momento/Janela 25x25 da banda HH (HHSM25), Contraste/Janela 31x31 da banda HH (HHCON31), Segundo Momento/Janela 19x19 da banda HV (HVSM19) e Contraste/Janela 25x25 da banda HV (HVCON25). A escolha destas bandas e os tamanhos das janelas foram baseados no trabalho Lu *et. al.* (2011).

O desafio na seleção de atributos é extrair atributos de radar que possam alcançar a acurácia do TM com maior número de classes possíveis. Métodos para extração de atributos e/ou de classificação contextual geralmente envolvem filtros o que implicam em certa perda de resolução espacial especialmente em regiões de transição.

Os produtos considerados operacionais de radar tem espaçamento ao redor de 12.5, resolução ao redor de 18 metros e número de *looks* igual a três. Um conjunto de 2x2 pixels de radar ocupa mais ou menos uma área equivalente a um pixel de TM com resolução de aproximadamente 30 metros. Uma forma alternativa é usar média ponderada em região 3x3. Uma área de 3x3 para TM (90m x 90m) corresponderia a uma área de 7x7 (87,5m x 87,5m) em radar, caso típico de espaçamento de 12.5m.

Desta forma, foram analisados cinco cenários, os quais são: **Cenário 1** - HH e HV, **Cenário 2** - HH & HHCV7 & HV & HVCV7, **Cenário 3** - HH & HHCV7, **Cenário 4** - HV & HVCV7, **Cenário 5** (HH, HV, HHSM25, HHCON31, HVSM19 e HVCON25).

Como o intuito deste trabalho é utilizar o método de classificação supervisionado, utilizaram-se regiões de interesse (ROIs) da imagem como ponto de treinamento para a classificação. Estas ROIs foram selecionadas de um banco de dados resultante do trabalho de campo realizado em 09/09/2009, os quais contêm a localização geográfica, fotos e comentários sobre as áreas visitadas. Desta forma, 2/3 das amostras obtidas em trabalho de campo na região do Amazonas serão utilizadas como conjunto de treinamento e 1/3 para validação das classificações supervisionadas pontuais. A matriz de confusão e a estatística *Kappa* foram utilizadas como métricas finais de validação nas classificações realizadas.

Os aplicativos utilizados para o processamento dos dados foram: ENVI+IDL 4.5 e WEKA 3.7. O software ENVI foi utilizado para registro, classificações e validações das imagens, já o WEKA foi utilizado para a realização de análises das bandas de texturas.

3. Classificação Supervisionada

Classificação supervisionada é uma atividade preditiva, em que consiste na generalização de amostras a partir de respostas conhecidas utilizadas para classificar novos exemplos. A partir de um conjunto de treinamento constrói-se um modelo para cada classe baseado nas características dos dados. As amostras obtidas em trabalho de campo, na região do Amazonas, foram utilizadas como conjunto de treinamento para as classificações supervisionadas por Máxima Verossimilhança (*Maximum Likelihood* - ML) com *Iterated Conditional Modes* (ICM) (contextual) e Máquinas de Vetores Suporte (*Support Vector Machine* - SVM) (pontual).

3.1. Máxima Verossimilhança (Maximum Likelihood - ML)

A classificação por Máxima Verossimilhança (ML) é uma técnica de classificação supervisionada pontual, sendo uma das mais utilizadas para dados de sensoriamento remoto (RICHARDS, JIA, 2006). No processo de classificação ML é extraído um vetor de atributos e calculada a probabilidade de um pixel r pertencer a cada uma das classes ω_i definidas na fase de treinamento (Equação 1). Em seguida, associam-se os pixels da imagem à classe que apresentar a maior probabilidade de pertencer, obedecendo ao seguinte critério de decisão (RICHARDS, JIA, 2006).

$$r \in \omega_i \text{ se } g_i(r) > g_j(r) \text{ para qualquer } j \neq i \quad (1)$$

Onde, $g_i(r)$ é chamada de função discriminante. Admitindo uma distribuição normal para cada uma das classes, a função discriminante pode ser calculada pela Equação 2 (RICHARDS, JIA, 2006).

$$g_i(r) = \ln[p(\omega_i)] - \frac{1}{2} \ln|\sum_i i| - \frac{1}{2} (r - m_i)^t \sum_i^{-1} (r - m_j) \quad (2)$$

Onde, m_i e \sum_i são vetor média e a matriz de covariância dos dados da classe da classe ω_i ; e $[p(\omega_i)]$ é a probabilidade a priori de x pertencer à classe ω_i .

Para melhorar o resultado da classificação foi utilizada uma combinação dos classificadores ML e *Iterated Conditional Modes* (ICM). O classificador ML-ICM, possui características semelhantes às do classificador ML, porém associa à classificação a informação contextual e espacial da imagem, reprocessando os resultados anteriores (GABOARDI, 2002).

3.2. Support Vector Machine (SVM)

O classificador *Support Vector Machine* (SVM) possui boa capacidade de generalização e é independente da distribuição dos dados. Este método consiste em encontrar o hiperplano de separação entre amostras de treinamento que possua maior margem. O hiperplano de separação é uma função da Equação 3 (THEODORIDIS, KOUTROUMBAS, 2008).

$$f(x) = w^T \cdot \phi(x) + b \quad (3)$$

onde w^T representa o transposto do vetor ortogonal ao hiperplano de separação, $b/\|w\|$ é a distância do hiperplano à origem e $\phi(x)$ é uma função adotada, caso necessário, para remapear os vetores em um novo espaço (THEODORIDIS, KOUTROUMBAS, 2008).

Os parâmetros utilizados no ENVI para o classificador SVM são: Kernel Type -> Radial Basic Function; Gamma in Kernel Funcion -> 0.5; Penalty Parameter -> 100; Pyramid Levels -> 0; Classification Probability Threshold -> 0.

4. Resultados

4.1. Seleção de Bandas de Texturas

As Figuras 1 e 2 apresentam, respectivamente, a Média e a Variância do Coeficiente de Variação da banda HH para Janelas de tamanho 5x5 a 31x31 para avaliação das 13

classes iniciais de análise. As classes Regeneração_inicial, Regeneração_antiga, Floresta_degradada, e Floresta_primária_exploração possuem comportamentos praticamente constantes na variação do tamanho das janelas para as duas medidas em questão, com ressalva entre as janelas 5x5 e 9x9, em que possuem uma queda pela metade a cada aumento do tamanho da janela. As outras classes, entretanto, não possuem comportamento uniforme na distribuição dos dados. A média está entre 0,200 e 0,400 e a variância está entre 0,000 e 0,0009, ao longo do aumento do tamanho das janelas, aproximadamente.




Figura 1. Média do Coeficiente de Variação – HH Janelas de 5 a 31.




Figura 2. Variância do Coeficiente de Variação – HH Janelas de 5 a 31.

As Figuras 3 e 4 apresentam, respectivamente, a Média e a Variância do Coeficiente de Variação da banda HV para Janelas de tamanho 5x5 a 31x31 para avaliação das 13 classes. O comportamento da banda HV em diferentes tamanhos de janelas apresentou-se comportamento mais similar ao longo da variação nas análises de cada classe, tanto para a média quanto para a variância. As classes Regeneração_inicial, Regeneração_antiga, Floresta_degradada, Floresta_primária_exploração e também Floresta_Primária possuem comportamentos praticamente constantes na variação do tamanho das janelas para as duas medidas em questão, com ressalva para a variância entre as janelas de 5x5 e 9x9 que, assim como na banda HH, diminui pela metade a cada faixa de alteração. A média está entre 0,000 e 0,025 e a variância está entre 0,200 e 0,045, ao longo do aumento do tamanho das janelas, aproximadamente.




Figura 3. Média do Coeficiente de Variação – HV Janelas de 5 a 31.




Figura 4. Variância do Coeficiente de Variação – HV Janelas de 5 a 31.

4.2. Análise de Resultados

A Figura 5 apresenta respectivamente as imagens classificadas por ML (54.18% de acurácia total) e SVM (66.36% de acurácia total) do Cenário 2 (HH, HHCV7, HV, HVCV7).

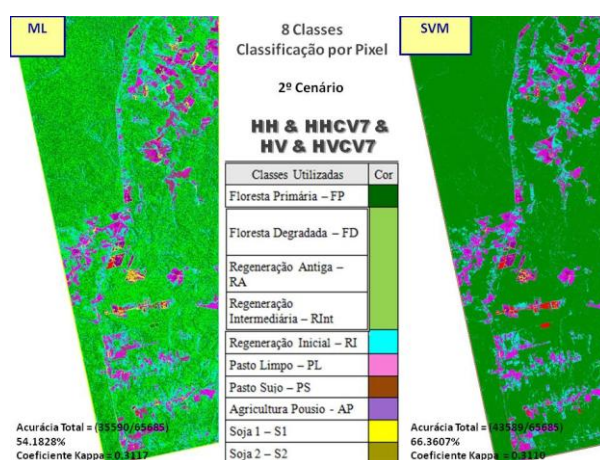


Figura 5. Cenário 2 – ML versus SVM – Acurácia Total.

A Tabela 2 apresenta o resultado da classificação ML por Matriz de Confusão para o Cenário2: **FD+RInt+RA 63.60%** (27.68% confusão com FP), FP 52.20% (40.52% confusão com FD+RInt+RA), PL 47.14% (33.11% confusão com AP), PS 51.07% (34.66% confusão com PL), RI 54.06% (25.15% confusão com FD+RInt+RA), AP 13.60% (52.49% confusão com S1), S1 29.99% (69.89% confusão com AP) e **S2 92.37%**.

A Tabela 3 apresenta o resultado da classificação SVM por Matriz de Confusão para o Cenário2: FD+RInt+RA 0.0% (98.42% confusão com FP), **FP 99.14%**, PL 67.97% (20.54% confusão com AP), PS 31.79% (47.88% confusão com PL), RI 42.02% (48.94% confusão com FP), AP 35.05% (37.63% confusão com PL e 20.43% confusão com S1), S1 20.15% (78.11% confusão com AP) e **S2 87.11%**.

Tabela 2. Cenário 2 – ML: Matriz de Confusão.

8 Classes/PIXEL- Cenário 2 - ML									Acurácia do Usuário %
Classe	FD+RInt+RA	FP	PL	PS	RI	AP	S1	S2	
FD+RInt+RA	66.60	40.52	0.03	0.00	25.15	0.00	0.00	0.00	39.40
FP	27.68	52.20	0.07	0.00	3.43	0.00	0.00	0.00	81.96
PL	0.01	0.00	47.14	34.66	1.50	17.32	0.00	1.58	62.48
PS	0.22	0.00	10.66	51.07	15.86	0.06	0.00	2.89	52.87
RI	5.49	7.27	3.75	14.01	54.06	12.22	0.12	3.16	20.71
AP	0.00	0.00	33.11	0.00	0.00	13.60	69.89	0.00	9.30
S1	0.00	0.00	5.20	0.20	0.00	52.49	29.99	0.00	33.31
S2	0.00	0.00	0.03	0.07	0.00	4.31	0.00	92.37	82.59
Total	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	
Acurácia do Produtor %	66.60	52.20	47.14	51.07	54.06	13.60	29.99	92.37	

Tabela 3. Cenário 2 – SVM: Matriz de Confusão.

8 Classes/PIXEL- Cenário 2 - SVM									Acurácia do Usuário %
Classe	FD+RInt+RA	FP	PL	PS	RI	AP	S1	S2	
FD+RInt+RA	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
FP	98.42	99.14	0.39	1.11	48.94	0.00	0.00	0.00	69.82
PL	0.00	0.00	67.97	47.88	3.29	37.63	1.68	8.68	58.04
PS	0.04	0.00	5.89	31.79	5.75	0.00	0.00	3.95	60.47
RI	1.55	0.86	4.15	19.22	42.02	0.84	0.06	0.00	45.98
AP	0.00	0.00	20.54	0.00	0.00	35.05	78.11	0.00	22.87
S1	0.00	0.00	1.02	0.00	0.00	20.43	20.15	0.26	48.27
S2	0.00	0.00	0.03	0.00	0.00	6.05	0.00	87.11	76.44
Total	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	
Acurácia do Produtor %	0.00	99.14	67.97	31.79	42.02	35.05	20.15	87.11	

A Figura 6 apresenta respectivamente as imagens classificadas por ML (67.91% de acurácia total) e SVM (72.87% de acurácia total) do Cenário 5 (HH, HHSM25, HHCON31, HV, HVSM19, HVCON25).

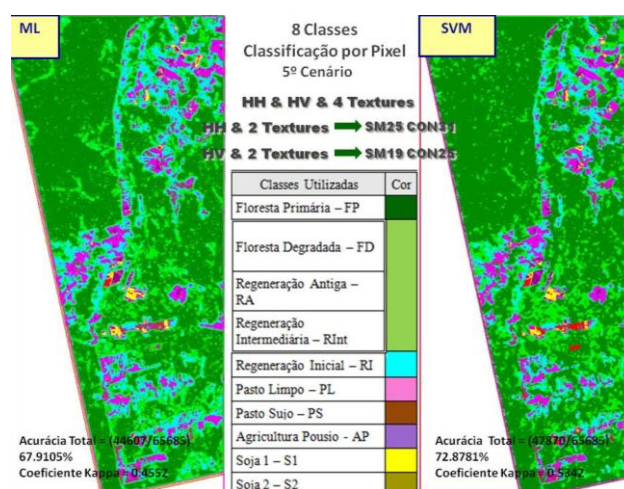


Figura 6. Cenário 5 – ML versus SVM – Acurácia Total.

A Tabela 4 apresenta o resultado da classificação ML por Matriz de Confusão para o Cenário5: FD+RInt+RA 49.10% (43.51% confusão com FP), **FP 80.03%** (17.32% confusão com FD+RInt+RA), PL 68.37% (16.75% confusão com AP), PS 17.39% (44.50% confusão com PL e 38.11% confusão com RI), **RI 79.98%** (13.20% confusão com FD+RInt+RA), AP 0.30% (44.70% confusão com S1 e 43.02% confusão com PL), S1 61.67% (33.41% confusão com Agricultura_Pousio) e S2 69.74%.

A Tabela 5 apresenta o resultado da classificação SVM por Matriz de Confusão para o Cenário5: FD+RInt+RA 61.41% (36.93% confusão com FP), **FP 82.79%** (17.18% confusão com FD+RInt+RA), **PL 78.37%**, PS 27.69% (59.22% confusão com PL), **RI 71.76%** (21.32% confusão com FD+RInt+RA), AP 6.71% (58.66% confusão com Soja1), Soja1 45.92% (52.29% confusão com Agricultura_Pousio) e **Soja2 90.53%**.

Tabela 4. Cenário 5 – ML: Matriz de Confusão.

8 Classes/PIXEL- Cenário 5 - ML									Acurácia do Usuário %
Classe	FD+RInt+RA	FP	PL	PS	RI	AP	S1	S2	
FD+RInt+RA	49.10	17.32	0.00	0.00	13.20	0.00	0.00	0.00	52.68
FP	43.51	80.03	0.00	0.00	0.15	0.00	0.00	0.00	81.82
PL	0.00	2.30	68.37	44.50	0.00	43.02	4.34	10.79	46.21
PS	0.67	0.01	10.57	17.39	6.67	3.30	0.00	12.89	28.43
RI	6.73	0.35	3.79	38.11	79.98	6.17	0.58	2.89	44.78
AP	0.00	0.00	16.75	0.00	0.00	0.30	33.41	0.00	0.46
S1	0.00	0.00	0.53	0.00	0.00	44.70	61.67	3.68	57.85
S2	0.00	0.00	0.00	0.00	0.00	2.52	0.00	69.74	86.32
Total	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	
Acurácia do Produtor %	49.10	80.03	68.37	17.39	79.98	0.30	61.67	69.74	

Tabela 5. Cenário 5 – SVM: Matriz de Confusão.

8 Classes/PIXEL- Cenário 5 - SVM									
Classe	FD+RInt+RA	FP	PL	PS	RI	AP	S1	S2	Acurácia do Usuário%
FD+RInt+RA	61.41	17.18	0.30	0.00	21.32	0.00	0.00	0.00	57.79
FP	36.93	82.79	0.00	0.00	0.00	0.00	0.00	0.00	84.59
PL	0.00	0.00	78.37	59.22	0.00	22.71	1.74	0.26	64.35
PS	0.00	0.00	10.50	27.69	6.91	0.84	0.00	0.79	47.01
RI	1.66	0.03	2.21	13.09	71.76	1.38	0.06	0.00	72.25
AP	0.00	0.00	8.53	0.00	0.00	6.71	52.29	0.00	8.79
S1	0.00	0.00	0.10	0.00	0.00	58.66	45.92	8.42	43.88
S2	0.00	0.00	0.00	0.00	0.00	9.71	0.00	90.53	67.98
Total	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	
Acurácia do Produtor%	61.41	82.79	78.37	27.69	71.76	6.71	45.92	90.53	

5. Considerações Finais

As classificações por ML e SVM apresentaram melhores valores *Kappa* para os Cenários 2 e 5. Tanto ML quanto SVM diferenciaram melhor as classes FP e S2. Para o cenário 2 não foi satisfatório a discriminação da classe FD+RInt+RA através do método SVM, bem como para o cenário 5 a classe AP. Tanto para o cenário 2 quanto para o 5 não foi satisfatório a discriminação da classe AP utilizando o método ML.

Referências

- GABOARDI, C. (2002) Utilização de imagem de coerência SAR para classificação do uso da terra: Floresta Nacional do Tapajós. 2002. 139 p. (INPE-9612-TDI/842). Tese (Doutorado em Sensoriamento Remoto) - INPE, São José dos Campos-SP. 2002.
- HESS, L.L.; MELACK, J.M.; SIMONETT, D.S. (1990) Radar detection of flooding beneath the forest canopy: a review. *International Journal of Remote Sensing*, v. 11, p. 1313-1325.
- LU, D.; LI, G.; MORAN, E.; DUTRA, L. V.; BATISTELLA, M. (2011) A comparison of multisensor integration methods for land cover classification in the Brazilian Amazon. *GISCI REMOTE SENS*, n. 48, p. 345-370.
- MEDEIROS, J. S. (1999) Bancos de Dados Geográficos e Redes Neurais Artificiais: Tecnologias de Apoio à Gestão de Território. Tese (Doutorado). Universidade de São Paulo (USP), SP.
- RICHARDS, J. A.; JIA X. (2006) *Remote sensing digital image analysis: an introduction*. 4 ed. Berlin: Springer-Verlag, 439 p.
- SEMA (SECRETARIA DE ESTADO DE MEIO AMBIENTE) (2012) Decreto de criação da FLONA do Tapajós - 73.684 - 19/02/1974. Disponível em: <http://www.sema.pa.gov.br/interna.php?idconteudocoluna=2018&idcoluna=9&titulo_conteudocoluna=73684>. Acesso em: Agosto/2012.
- THEODORIDIS, S.; KOUTROUMBAS, K. (2008) *Pattern Recognition*, Fourth Edition. 4th. ed. [S.l.]: Academic Press.