

Utilização de técnicas de Detecção Remota na identificação de *Acacia* sp. na Região Centro Sul de Portugal Continental

Filipe Domingos Martins

Dissertação apresentada ao Instituto Politécnico de Castelo Branco para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Sistemas de Informação Geográfica em Recursos Agro-Florestais e Ambientais, realizada sob a orientação científica da Doutora Cristina Maria Martins Alegria, Professora Adjunta da Unidade Departamental de Recursos Naturais e Desenvolvimento Sustentável do Instituto Politécnico de Castelo Branco e do Doutor Artur José Freire Gil, Investigador em Detecção Remota Ambiental no CITA-A (Centro de Investigação em Tecnologias Agrárias dos Açores), no Departamento de Biologia da Universidade dos Açores.

Agradecimentos

A elaboração do trabalho teve o contributo de pessoas a quem não posso deixar de agradecer.

Um grande agradecimento aos meus orientadores Doutor Artur Gil pela orientação científica, acompanhamento, conselhos e amizade no desenvolvimento do trabalho e à Professora Doutora Cristina Alegria pela confiança e entusiasmo depositado no tema do trabalho e “Alegria” contagiante.

Agradeço também à minha namorada Isabel pelo apoio constante e pôr manter o ânimo sempre em alta.

Aos meus pais e irmãos pelo apoio, amor e conselhos que sempre me dão.

Aos demais professores e colegas que me apoiaram indiretamente durante o período em que decorreu este trabalho.

Palavras chave

Deteção Remota, ASTER, Cartografia de Vegetação, Cartografia de Ocupação do Solo, Espécies Exóticas Invasoras, *Acacia dealbata* Link.

Resumo

A deteção remota é uma ferramenta que permite a cartografia e monitorização de espécies exóticas invasoras e providencia um meio para detetar alterações na ocupação do solo, derivado do recurso a múltiplos sensores com diferentes resoluções espectrais, espaciais e temporais.

As espécies exóticas invasoras são unanimemente consideradas como uma das maiores ameaças à biodiversidade a nível global, alterando ecossistemas e levando a uma cada vez maior uniformização do coberto vegetal.

A *Acacia dealbata* Link é considerada como uma das maiores invasoras a nível nacional, sendo conhecidas ocupações da espécie em todo o território nacional.

Na Região Centro Sul de Portugal Continental, a invasão por *Acacia dealbata* tem vindo a atingir proporções consideráveis, não estando no entanto quantificadas zonas de ocorrência.

Através da utilização de técnicas de deteção remota estudou-se a possibilidade de produzir por processos de classificação assistida a cartografia das áreas de infestação da espécie *Acacia dealbata*, utilizando imagens de satélite multiespectrais ASTER de duas diferentes épocas do ano (março, mês de floração da espécie-alvo; agosto, época mais seca). Para a classificação assistida utilizaram-se métodos supervisionados, mais especificamente, um classificador paramétrico convencional - classificador de Máxima Verosimilhança (Maximum Likelihood) e dois métodos não paramétricos - classificador de Máquinas de Vetores de Suporte (Support Vector Machine) e Redes Neurais Artificiais (Artificial Neural Networks - ANN).

Os resultados globais demonstraram maior precisão de classificação no mês de março, com o classificador da máxima verosimilhança a registar melhores resultados ($Kappa > 0,85$). A classificação da *Acacia dealbata* obteve excelentes resultados no classificador da máxima verosimilhança ($K=1$), daí se podendo afirmar que a classificação por imagens multiespectrais ASTER pode constituir uma ferramenta viável para a monitorização e delimitação de *Acacia dealbata* na zona centro sul de Portugal Continental. No que diz respeito à Cartografia de Ocupação do Solo mais convencional, os melhores resultados globais são obtidos pelo classificador da máxima verosimilhança no mês de março ($K=0,89$), sendo que todas as classes individuais registaram índices Kappa superior a 0,82, concluindo-se a real aplicabilidade de imagens multiespectrais ASTER na classificação de classes genéricas de ocupação do solo.

Keywords

Remote Sensing, ASTER, Vegetation Mapping, Land Use/Land Cover Mapping, Invasive Alien Species, *Acacia dealbata* Link.

Abstract

Remote sensing is a tool that allows the cartography and monitoring of invasive alien species and provides a way to detect land use alterations, derived from the use of multiple sensors with different spectral, spatial and temporal resolution.

Invasive alien species are universally seen as a major threat to global biodiversity, altering ecosystems and increasing the uniformity of the vegetation.

Acacia dealbata Link is considered one of the largest national invasive species, being known occupations of the specie in all the domestic territory.

In the South Center Region of Portugal Continental, the invasion by *Acacia dealbata* has achieved considerable proportions, and is not yet quantified areas of occurrence.

Through the use of remote sensing techniques it was studied the possibility to produce by assisted classification processes the cartography of the areas of infestation of the species *Acacia dealbata*, using ASTER multispectral satellite images of two different seasons (March, month of flowering of the target species; August, driest time). To the assisted classification there were used supervised methods, more specifically, a conventional parametric classifier - Maximum Likelihood and two non-parametric methods - Support Vector Machine and Artificial neural Networks.

The overall results showed the highest classification accuracy in the month of March, with better results in the maximum likelihood classifier ($\kappa > 0.85$). The classification of *Acacia dealbata* obtained excellent results in the maximum likelihood classifier ($K = 1$), there may be said that the classification of multispectral ASTER images can be a viable tool for monitoring and delineation of *Acacia dealbata* in the south center of Portugal Continental. Concerning the more conventional cartography of the Land Use Mapping, the best overall results are obtained by maximum likelihood classifier in March ($K = 0.89$), and all classes Individual Kappa recorded more than 0.82 , concluding the real applicability of multispectral ASTER images in the classification of generic land use classes.

Índice geral

1. Introdução.....	1
2. Estado da arte	3
2.1 Breve resenha histórica da deteção remota por satélite	5
2.2 Fundamentos da deteção remota ótica	7
2.2.1 O espectro eletromagnético	8
2.2.2 Características dos sensores	9
2.3 O sensor ASTER (Advanced Spaceborne Thermal and Reflection Radiometer)	10
2.4 Sistemas de classificação de imagens digitais	12
2.4.1 Áreas de treino	13
2.4.2 Medidas de separabilidade espectral.....	13
2.4.3 Classificação	14
2.4.4 Pós-processamento	18
2.5 Invasões biológicas e espécies exóticas invasoras	21
2.5.1 Invasões biológicas.....	21
2.5.2 Etapas do processo de invasão.....	21
2.5.3 Impacte das invasões biológicas.....	22
2.6 Situação da <i>Acacia dealbata</i> em Portugal Continental.....	23
2.7 Deteção remota aplicada à cartografia e monitorização de vegetação exótica invasora. 25	
3. Materiais e métodos.....	29
3.1 Área de estudo	30
3.2 Dados utilizados	31
3.2.1 Imagens de satélite	31
3.2.2 Modelo digital do terreno	32
3.2.3 Sítios de treino	32
3.3 Software utilizado	33
3.4 Pré-processamento das imagens ASTER.....	33
3.4.1 Correção geométrica	33

3.4.2 Correção atmosférica	34
3.5 Definição da legenda inicial	36
3.6 Separabilidade espectral	37
3.7 Processamento	37
3.8 Pós-processamento	39
4. Apresentação e discussão de resultados.....	41
4.1 Legenda original - 9 classes	41
4.1.1 Separabilidade espectral	41
4.1.2 Classificação	43
4.2 Legenda alterada 1 - 7 classes.....	49
4.2.1 Separabilidade espectral	49
4.2.2 Classificação	50
4.3 Legenda alterada 2 - 6 classes.....	56
4.3.1 Separabilidade espectral	56
4.3.2 Classificação	57
4.4 Legenda alterada 3 - 5 classes.....	63
4.4.1 Separabilidade espectral	63
4.4.2 Classificação	63
4.5 Legenda alterada 4 - 4 classes.....	69
4.5.1 Separabilidade espectral	69
4.5.2 Classificação	70
4.6 <i>Acacia dealbata</i> - síntese comparativa	74
4.6.1 Comparação de índices Kappas.....	74
4.6.2 Análise de áreas de ocupação	75
5. Conclusões	79
Referências Bibliográficas.....	83

Índice de figuras

Figura 1- Componentes de um sistema de detecção remota.	4
Figura 2 - Evolução histórica dos sistemas de Detecção Remota.....	5
Figura 3 - Esquema representativo dos elementos fundamentais da detecção remota	7
Figura 4 - Flutuações dos campos elétrico e magnético.	8
Figura 5 - Espectro eletromagnético	8
Figura 6 - Região espectral do sensor ASTER.	11
Figura 7 - Distribuição gaussiana das classes hipotéticas ω_1 , ω_2 e ω_3	15
Figura 8 - Distribuição gaussiana das classes hipotéticas ω_1 , ω_2 e ω_3	15
Figura 9 - Esquema de classificação por MVS	16
Figura 10 - Principais etapas de um processo de invasão	22
Figura 11 - Publicações sobre aplicações de SIG e DR no mapeamento de invasoras	26
Figura 12 - Esquema metodológico	30
Figura 13 - Localização geográfica da área de estudo.	30
Figura 14 - <i>Corine Land Cover</i> 2006 da área de estudo.	31
Figura 15 - Parâmetros da correção geométrica (imagem ASTER de agosto de 2005 - subsistema VIF).	34
Figura 16 - Modelo FLAASH (imagem ASTER de agosto de 2005).	35
Figura 17 - Imagem ASTER original e final (Banda 1 de agosto de 2005).	35
Figura 18 - Parâmetros do MV (agosto de 2005).	37
Figura 19 - Parâmetros do MVS (agosto 2005).	38
Figura 20 - Parâmetros das RNA (agosto 2005).	38
Figura 21 - Mapa de ocupação do solo da legenda original, classificador da MV - - março 2007. .	47
Figura 22 - Avaliação do índice de exatidão do produtor dos classificadores, legenda original - agosto de 2005 e março de 2007.....	48
Figura 23 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda original - agosto de 2005 e março de 2007.....	48
Figura 24 - Determinação do índice Kappa dos classificadores, legenda original - agosto de 2005 e março de 2007.....	49
Figura 25 - Mapa de ocupação do solo da legenda alt1, classificador da MV - março 2005	54
Figura 26 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.....	55
Figura 27 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.....	55

Figura 28 - Determinação do índice Kappa dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.....	56
Figura 29 - Mapa de ocupação do solo da legenda alt2, classificador da MV - março de 2007. ...	61
Figura 30 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.....	62
Figura 31 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.....	62
Figura 32 - Determinação do índice Kappa dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.....	62
Figura 33 - Mapa de ocupação do solo da legenda alt3, classificador da MV - março 2007.	67
Figura 34 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.....	68
Figura 35 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.....	68
Figura 36 - Determinação do índice Kappa dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.....	68
Figura 37 - Mapa de ocupação do solo da legenda alt4, classificador da MV - março 2007.	72
Figura 38 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.....	73
Figura 39 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.....	73
Figura 40 - Determinação do índice Kappa dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.....	74
Figura 47 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda original - Agosto de 2005.	77
Figura 48 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda original - Março de 2007.	77
Figura 49 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 1 - Agosto de 2005.....	77
Figura 50 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 1 - Março de 2007.	77
Figura 51 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 2 - Agosto de 2005.....	78
Figura 52 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 2 - Março de 2007.	78
Figura 53 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 3 - Agosto de 2005.....	78
Figura 54 - Mapa de ocupação de <i>Acacia dealbata</i> da legenda alterada 3 - Março de 2007.	78

Índice de tabelas

Tabela 1 - Características dos subsistemas ASTER.....	12
Tabela 2 - Representação de uma matriz de confusão.	19
Tabela 3 - Qualidade da classificação dos valores Kappa.	20
Tabela 4 - Caracterização morfológica da <i>Acacia dealbata</i>	24
Tabela 5 - Área (km ²) das principais culturas da área de estudo - Corine Land Cover 2006.	31
Tabela 6 - Informação geográfica auxiliar utilizada.	32
Tabela 7 - Nomenclatura de ocupação do solo.	36
Tabela 8 - Valores de separabilidade da legenda original - agosto de 2005.	42
Tabela 9 - Valores de separabilidade da legenda original - março de 2007.....	43
Tabela 10 - Matriz de confusão da legenda original - agosto de 2005.....	45
Tabela 11 - Matriz de confusão da legenda original - março de 2007.	46
Tabela 12 - Valores de exatidão global e Kappa- legenda original.	46
Tabela 13 - Área (km ²) das classes da legenda original, classificador da MV.	47
Tabela 14 - Valores de separabilidade da legenda alterada 1 - agosto de 2005.....	49
Tabela 15 - Valores de separabilidade da legenda alterada 1 - março de 2007.....	50
Tabela 16 - Matriz de confusão da legenda alterada 1 - agosto de 2005.	52
Tabela 17 - Matriz de confusão da legenda alterada 1 - março de 2007.	53
Tabela 18 - Valores de exatidão global e Kappa- legenda alterada 1.	53
Tabela 19 - Área (km ²) das classes da legenda alt1, classificador da MV.....	54
Tabela 20 - Valores de separabilidade da legenda alterada 2 - agosto de 2005.....	56
Tabela 21 - Valores de separabilidade da legenda alterada 2 - março de 2007.....	57
Tabela 22 - Matriz de confusão da legenda alterada 2 - agosto de 2005.	59
Tabela 23 - Matriz de confusão da legenda alterada 2 - março de 2007.	59
Tabela 24 - Valores de exatidão global e Kappa- legenda alterada 2.	60
Tabela 25 - Área (km ²) das classes da legenda alt2, classificador da MV.....	61
Tabela 26 - Valores de separabilidade da legenda alterada 3 - agosto de 2005.....	63
Tabela 27 - Valores de separabilidade da legenda alterada 3 - março de 2007.....	63
Tabela 28 - Matriz de confusão da legenda alterada 3 - agosto de 2005.	65
Tabela 29 - Matriz de confusão da legenda alterada 3 - março de 2007.	66
Tabela 30 - Valores de exatidão global e Kappa - legenda alterada 3.	66
Tabela 31 - Área (km ²) das classes da legenda alt3, classificador da MV.....	67
Tabela 32 - Valores de separabilidade da legenda alterada 4 - agosto de 2005.....	69
Tabela 33 - Valores da separabilidade da legenda alterada 4 - março de 2007.....	69
Tabela 34 - Matriz de confusão da legenda alterada 4 - agosto de 2005.	71

Tabela 35 - Matriz de confusão da legenda alterada 4 - março de 2007.	71
Tabela 36 - Valores de exatidão global e Kappa- legenda alterada 4.	72
Tabela 37 - Área (km ²) das classes da legenda alt4.	73
Tabela 38 - Valores de Kappa da classe “Acácias”.	75
Tabela 39 - Área (km ²) da classe “Acácias”.....	76

Lista de abreviaturas

ADL - Análise Discriminante Linear

AIS - Airborne Imaging Spectrometer

AISA - Compact Airborne Spectrographic Imager

APA - Agência Portuguesa do Ambiente

ASTER - Advanced Spaceborne Thermal Emission and Reflection Radiometer

AVIRIS - Airborne Visible Infrared Imaging Spectrometer

CASI - Compact Airborne spectrographic imager

CLC - Corine Land Cover

COA - Carta de Ocupação do Solo

DGRF - Direcção-Geral dos Recursos Florestais

DR - Deteção Remota

DT - Divergência Transformada

EDCDAAC - Eros Data Center Distributed Active Archive Center

EEA - European Environment Agency

EG - Exatidão Global

EOS - Earth Observing System

EOSDIS - Earth Observing System Data and Information System

EP - Exatidão do Produtor

ERS-1 - European Remote Sensing Satellite

ERTS-1 - Earth Resources Technology Satellite

ESA - European Space Agency

ETM + - Enhanced Thematic Mapper +

EU - Exatidão do Utilizador

FLAASH - Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes

FLIR - Forward_Looking Radar

HDF - Hierarchical Data Format

HYDICE - Hyperspectral Digital Imagery Collection Experiment

IGP - Instituto Geográfico Português

IM - Infravermelho Médio

IT - Infravermelho Térmico

IUCN - International Union for the Conservation of Nature

JERS-1 - Japanese Earth Resources Satellite 1

K - Kappa

KC - Kappa Condicional

LV - Largura de Varrimento

MDM - Mínima Distância de Mahalanobis

MMF - Maximum Matching Feature

MODTRAN - Moderate Resolution Transmission Model

MV - Máxima Verosimilhança

MVS - Máquinas de Vetores de Suporte

NASA - National Aeronautics and Space Administration

ND - Número Digital

NDVI - Normalized Difference Vegetation Index

REM - Radiação Eletromagnética

RNA - Redes Neurais Artificiais

SAM - Spectral Angle Mapper

SIG - Sistemas de Informação Geográfica

SLAR - Side-Looking Airborne Radar

SLC - Scan Line Corrector

SPOT - Système pour l'Observation de la Terre

TM - Thematic Mapper

VIF - Visível e Infravermelho Próximo

WFW - Working for Water

1. Introdução

É comum afirmar-se que as espécies invasoras, decretadas como tal em Portugal, pelo Decreto-Lei 565/99, são consideradas como uma das maiores ameaças à biodiversidade de espécies, alterando com muita frequência os ecossistemas. Atualmente são consideradas umas das principais componentes das alterações globais, contribuindo para a uniformização global das espécies (Marchante 2001).

A *Acacia dealbata* Link (mimosa) é uma espécie do género *Leguminosae*, originária da Tasmânia - Austrália (Marchante *et al.* 2005). É uma espécie de crescimento rápido - de 1 a 1.5 metros ano, adaptado a climas temperados, ventos salgados, ao frio e gelo e temperaturas a rondar os 40°C (May *et al.* 2003). Cresce preferencialmente em terrenos frescos de vales ou margens de cursos de água, sendo também muito frequente ao longo de vias de comunicação (Marchante *et al.* 2005). O seu elevado potencial invasor advém da elevada produção de sementes, dispersão e longevidade no solo, assim como a estimulação das sementes pelo fogo (característica do clima mediterrânico no Verão), permitindo que áreas recentemente ardidas recuperem facilmente os seus povoamentos. Em Portugal, a *Acacia dealbata* é considerada, segundo Marchante *et al.* (2005), como provavelmente a invasora mais agressiva em sistemas terrestres, estando indicada como invasora pelo Decreto-Lei 565/99.

O fenómeno das plantas invasoras, que se regista numa grande diversidade de ecossistemas, e que abrange todas as regiões do mundo, tem suscitado a atenção da comunidade científica, dos gestores do território e do público em geral. Deste modo, torna-se fundamental a existência de ferramentas que permitam identificar e monitorizar alterações/invasões de plantas

exóticas invasoras, de forma a obter informação atualizada e fiável, para uma melhor gestão de áreas invadidas.

Métodos tradicionais para cartografar a distribuição de espécies invasoras, como levantamentos de campo, revisão de literatura e interpretação de mapas, não são eficazes, pois consomem muito tempo e comportam custos elevados (Xie *et al.* 2008). Por sua vez, a “deteção remota” e os “sistemas de informação geográfica” oferecem ferramentas com potencial para a produção de cartografia e monitorização das áreas ocupadas com espécies exóticas invasoras, assim como para a previsão de áreas suscetíveis de serem invadidas. As imagens de satélite oferecem vantagens bem documentadas desde que começaram a ser utilizadas, nomeadamente na variedade de dados multiespectrais, na vasta cobertura temporal e no baixo custo de aplicação (Van der Meer *et al.* 2002). É uma ferramenta importante para estudar terrenos morfologicamente complexos e ecossistemas normalmente inacessíveis.

Desde o seu aparecimento que as imagens de satélite têm servido de base a estudos de caracterização da ocupação do solo, sendo um meio extremamente eficaz para a delimitação de espécies invasoras, pois permitem desenvolver e avaliar classificadores automáticos para extração de informação (Plantier 2006). O uso de imagens multiespectrais possibilita a cobertura de grandes áreas espaciais, a deteção de alterações no coberto do solo através da análise de dados multitemporais, bem como a oportunidade para o processamento automático de imagem (Xie *et al.* 2008). Diversos estudos demonstram a aplicabilidade de imagens de satélite multiespectrais para a cartografia de espécies invasoras. São exemplos os trabalhos de Viana e Aranha (2005) na utilização de Landsat 7 ETM+ e ASTER para deteção de *Acacia dealbata*, o de Cobbing (2007) utilizando imagens Landsat 7 ETM+ na cartografia de *Acacia* sp. e o de Masocha e Skidmore (2011) para a cartografia de *Lantana camara* com recurso a imagens ASTER.

Na Região Centro Sul de Portugal Continental a invasão pela invasora *Acacia dealbata* tem vindo a atingir proporções consideráveis, não estando no entanto quantificável a sua real incidência no território, para possível erradicação/controlo futuro. Desta forma, o objetivo principal do estudo consiste na definição da abordagem metodológica mais adequada (época de obtenção da imagem; tipo de legenda adotada; classificador a aplicar) para a deteção e cartografia de *Acacia dealbata* em imagens ASTER na Região Centro-Sul de Portugal Continental.

Os objetivos específicos do presente estudo são os seguintes:

- explorar o potencial das imagens multiespectrais ASTER de dois períodos distintos do ano para cartografia de *Acacia dealbata*;
- analisar a separabilidade espectral de diferentes nomenclaturas de ocupação do solo, ajustadas às potencialidades das imagens ASTER;
- testar e comparar diferentes classificadores para análise dos padrões espectrais existentes nas imagens ASTER;
- produzir mapas de ocupação de *Acacia dealbata* na Região Centro Sul de Portugal Continental.

2. Estado da arte

A “Detecção Remota” (DR) é a ciência, o conjunto de tecnologias e a arte, que permite obter informação sobre objetos, áreas ou fenómenos, através da análise de informação adquirida por aparelhos de informação (sensores) sem contacto com o objeto, área, ou fenómeno em estudo (Rocha 2002).

Para a aquisição de imagens da superfície terrestre desde sensores instalados em plataformas espaciais, tem de existir uma interação energética, quer seja por reflexão da energia solar, de uma fonte energética artificial, ou por emissão própria do sensor.

Segundo Chuvieco (1995), um sistema de detecção remota, inclui os seguintes elementos (Figura 1):

- i. Fonte de Energia - que representa a origem da fonte energética detetada pelo sensor. Pode tratar-se de um foco de energia externa ao sensor, na qual temos uma detecção passiva, ou de um foco de energia emitida por este - detecção ativa. A fonte de energia mais importante é a solar.
- ii. Cobertura Terrestre - formada por diferentes tipos de vegetação, solos, água e construções artificiais, que recebem a emissão energética procedente de (i) e refletem-na de acordo com as suas características físicas.
- iii. Sistema Sensor - composto pelo sensor e pela plataforma que o sustenta. Tem como missão captar a energia proveniente das cobertas terrestres, codificá-la e gravá-la, ou envia-la diretamente para o sistema de receção.

- iv. Sistema de Recepção - local onde se recebe a informação transmitida pela plataforma, gravando-a num formato apropriado, podendo-se corrigir ou não, para posterior distribuição ao público.
- v. Intérprete - analisa a informação, normalmente em imagens digitais (podem ser também analógicas) convertendo-a em informação temática ou quantitativa, orientada de forma a facilitar o estudo necessário em gabinete.
- vi. Utilizador Final - encarregue de analisar o documento fruto da interpretação, podendo a partir deste tomar as decisões necessárias para o estudo.

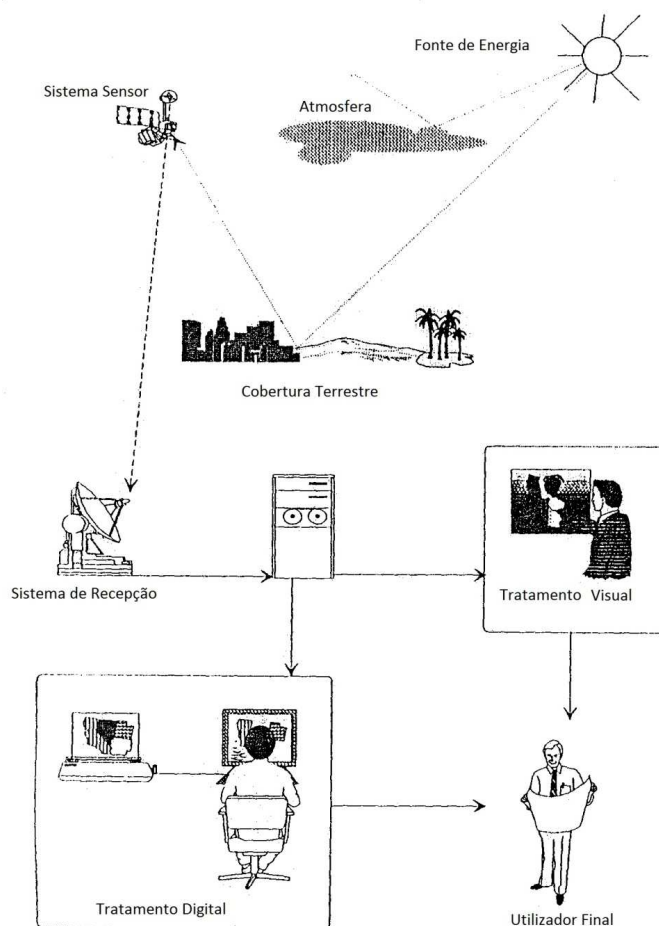


Figura 1- Componentes de um sistema de detecção remota (adaptado de Chuvieco 1995).

A crescente utilização de distintos sensores de observação terrestre tem vindo a originar uma enorme quantidade de informação, assim como uma nova forma de estudar a superfície terrestre. A detecção remota, juntamente com novas técnicas de armazenamento de dados e dos sistemas de informação geográfica (SIG), permite uma enorme quantidade de dados sobre o território, sendo alguns destes acessíveis em tempo real. Para o aproveitamento total destes recursos, a utilização dos computadores é uma opção inevitável. Em suma, a utilização conjunta destes recursos, ajudam a elaborar uma interpretação rápida e económica a partir de gabinete, uma vez que permitem abordar análises integradas, dificilmente viáveis com outros meios tradicionais (Chuvieco 1995).

2.1 Breve resenha histórica da detecção remota por satélite

O termo “Detecção Remota” apareceu pela primeira vez na literatura científica em 1960 (Novo e Ponzoni 2001) e significava simplesmente a aquisição de informações sem contacto físico com os objetos. Desde então o termo tem-se ligado com tecnologia e conhecimentos extremamente complexos derivados de diferentes campos que vão desde a física até a botânica e desde a engenharia eletrotécnica até a cartografia.

O campo da detecção remota representa a convergência de conhecimento derivado de duas grandes linhas de pesquisa. De um lado, a detecção remota é tributária da aerofotogrametria e da fotointerpretação, de outro lado, da pesquisa espacial e dos avanços tecnológicos por ela induzidos, resultando em sensores mais sensíveis, regiões espectrais ampliadas, métodos radiométricos, resoluções espaciais, entre outros. O crescimento tem sido vertiginoso, facilitando uma progressão notável, em quantidade e qualidade, na aquisição de informação para diversos campos científicos (Novo e Ponzoni 2001).




Figura 2 - Evolução histórica dos sistemas de Detecção Remota (adaptado de Chuvieco 1995).

Segundo Chuvieco (1995), o desenvolvimento inicial da detecção remota está cientificamente ligado ao desenvolvimento da fotografia e à pesquisa espacial. As fotografias aéreas foram o primeiro produto de detecção remota a serem utilizadas, quando Gaspar Felix de Tournachon, em 1859, obteve as primeiras fotografias aéreas a partir de um balão.

Nos anos seguintes assistiu-se a um desenvolvimento da observação fotográfica desde aviões, graças a importantes progressos em óticas fotográficas. Em 1909 Wilbur Wright efetuou a sua primeira fotografia aérea, abrindo caminho à observação terrestre a partir de plataformas remotas.

As fotografias aéreas coloridas começaram a estar disponíveis a partir de 1930, tendo-se nessa mesma época, iniciado os estudos para a produção de filmes sensíveis à radiação infravermelha. Com o início da II Guerra Mundial intensificaram-se os estudos sobre o processo de interação da radiação nessa faixa do espectro com os objetos com a finalidade de detecção de camuflagem.

Em 1954, foram desenvolvidos os sistemas de radares de captação de imagens - Forward-looking radar (FLIR), aparecendo em 1961 os radares de aquisição lateral - Side-looking airborne radar (SLAR).

No final da década de 50, os desenvolvimentos dos sistemas de navegação, permitiram conceber os primeiros aparelhos espaciais. Para este desenvolvimento em muito contribuiu a guerra fria entre os Estados Unidos e a URSS, o que levou a uma intensa investigação de parte a parte sobre o tema. O lançamento do satélite soviético Sputnik em 1957 despoletou uma série de missões civis e militares que permitiram uma cada vez maior exploração do nosso Planeta, surgindo a partir daí o advento dos sistemas orbitais de detecção remota.

Em 1960, a NASA pôs em órbita o primeiro satélite da série TIROS, com uma finalidade de observação meteorológica. Paralelamente houve também a utilização de câmaras fotográficas para a aquisição de fotografias da superfície terrestre durante as missões tripuladas da série Apollo.

É assim que na década de 70, com todo o feedback adquirido pelas anteriores missões espaciais, que a NASA, lança o primeiro satélite experimental de levantamento de recursos terrestres ERTS-1 (Earth Resources Technology Satellite). Esse satélite, e o sensor multiespectral que leva a bordo, modificaram o seu nome para Landsat em 1975, transformando-se no satélite de detecção remota de mais longa duração, existindo ainda atualmente com o Landsat 7. A partir do lançamento do Landsat, houve um incremento de interesse por parte da comunidade científica internacional por técnicas de detecção remota, surgindo uma multiplicidade de satélites com diversas características.

Na década de 80 foi lançado o vaivém Space Shuttle, o que marcou um novo rumo na exploração espacial. Entre 1981 e 1994 obtiveram-se 45 000 fotografias espaciais de domínio público tiradas pelo vaivém. Entre estas são de destacar as fotografias estereoscópicas, as quais permitiram gerar cartografia topográfica básica de média escala em países menos desenvolvidos. Ainda na década de 80, mais concretamente em 1986, foi lançado o satélite multiespectral SPOT (Système Pour l'Observation de la Terre), o qual resultou duma parceria entre a França, Bélgica e Suécia, tendo sido lançado outros satélites da mesma família em 1993, 1998 e 2002 (Vega e Isabel 2010).

A partir de 1982 começou a ser projetado o primeiro sensor hiperespectral pela NASA, o qual recebeu o nome de Airborne Imaging Spectrometer (AIS), o qual possuía 128 bandas espectrais contíguas e aerotransportado. Atualmente entre os sensores orbitais hiperespectrais encontram-se o sensor Hyperion no satélite EO-1 (2000) da NASA e o sensor CHRIS no satélite Proba (2001) da Agência Espacial Europeia. Entre os sensores hiperespectrais aerotransportados mais utilizados encontram-se o AVIRIS (Airborne Visible Infrared Imaging Spectrometer), HYDICE (Hyperspectral Digital Imagery Collection Experiment), CASI (Compact Airborne Spectrographic Imager) e ALSA (Compact Airborne Spectrographic Imager) (Shippert 2002).

Em 1991 a Agência Espacial Europeia lançou o seu primeiro satélite de detecção remota, com sensores radar, o ERS-1 (European Remote Sensing Satellite), lançando em 1995 o segundo satélite desta série, o ERS-2. O seu objetivo era complementar os sensores óticos a bordo do Landsat e SPOT. As suas aplicações eram muito variadas, no entanto as suas observações estavam mais orientadas para o estudo dos oceanos e da criosfera. Após este lançamento surgiram outros

sensores radar, como o JERS-1 (Japanese Earth Resources Satellite 1), o Radarsat (1995) e SIR-C/X-SAR (1994).

Em Setembro de 1999, foi lançado o primeiro satélite comercial de alta resolução espacial, o IKONOS-2 com 1 metro de resolução pancromática e 4 metros nas bandas multiespectrais. Após este lançamento surgiram novos satélites de alta resolução espacial como o Quickbird (2001), GeoEye 1 (2008), RapidEye (2008), WorldView 1 e 2 (2007 e 2009) 3 Pleiades-1 (2011) (Vega e Isabel 2010).

2.2 Fundamentos da deteção remota ótica

Como dito anteriormente, um dos principais objetivos da deteção remota é a aquisição de informação sobre a superfície da Terra para mapeamento e avaliação de recursos terrestres e monitorização ambiental. Todos os materiais, naturais e artificiais, da superfície terrestre, com temperatura superior a 0°C emitem, refletem, transmitem ou absorvem radiação eletromagnética (REM) (Novo e Ponzoni 2001).

Para melhor compreender os fundamentos da deteção remota, é necessário identificar os quatro elementos fundamentais, os quais podem ser representados através do esquema apresentado na figura 3:




Figura 3 - Esquema representativo dos elementos fundamentais da deteção remota (adaptado de Novo e Ponzoni 2001).

A REM é o elemento de ligação entre todos os elementos que se encontram nos vértices. São eles, a fonte de REM, que para o caso da aplicação das técnicas de deteção remota para estudos ambientais, é o Sol (pode ser também a Terra para os sensores passivos de micro-ondas e termais, podem ser antenas de micro-ondas para os sistemas radares); o sensor, que é o instrumento capaz de recolher e registrar a REM refletida ou emitida pelo alvo, e que representa o elemento do qual se pretende extrair informação (IBGE 2001).

A partir do esquema anterior compreende-se que o elemento fundamental das técnicas de deteção remota é a REM, que no vácuo propaga-se à velocidade da luz e a sua interação com o meio físico pode ser explicada através de dois modelos: o modelo quântico e o modelo ondulatório (Aggarwal 2003).

Sob a perspetiva do modelo quântico, a REM é concebida como o resultado da emissão de pequenos campos de energia, enquanto que sob a perspetiva do modelo ondulatório, a REM propaga-se na forma de ondas formadas pela oscilação dos campos elétrico e magnético. No modelo ondulatório a REM transmite-se de um lugar para o outro segundo um modo harmónico e contínuo, à velocidade da luz. A figura seguinte (4) apresenta um esquema da representação dos campos elétrico e magnético e as oscilações mencionadas (Novo e Ponzoni 2001).




Figura 4 - Flutuações dos campos elétrico e magnético (adaptado de Novo e Ponzoni 2001).

2.2.1 O espectro eletromagnético

O conjunto de comprimentos de onda que compõem a REM é conhecido como espectro eletromagnético, o qual é dividido num certo número de regiões espectrais. Com a tecnologia atualmente disponível, pode-se gerar ou detetar a radiação eletromagnética em comprimentos de onda na faixa de 108 metros a $0,01 \mu\text{m}$ (Aggarwal 2003).

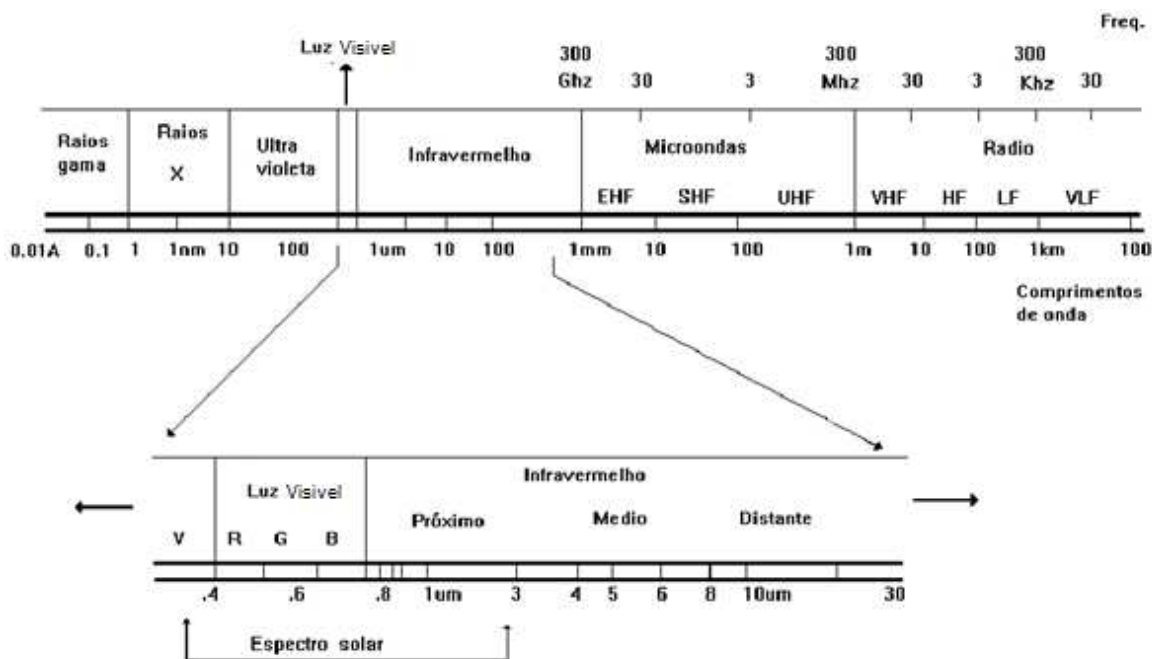


Figura 5 - Espectro eletromagnético (adaptado de Novo e Ponzoni 2001).

Segundo Chuvieco (1995), do ponto de vista da detecção remota, é de destacar uma série de bandas, que são mais frequentemente utilizadas:

- i. Espectro visível (luz visível) - $0,4$ a $0,7 \mu\text{m}$. É a única radiação eletromagnética que é visível pelo olho humano, coincidindo com os comprimentos de onda de maior radiação solar. Podem-se distinguir 3 bandas elementares, que são o azul (*Blue*) com radiação entre $0,4$ a $0,5 \mu\text{m}$, o verde (*Green*) com radiação entre $0,5$ a $0,6 \mu\text{m}$ e vermelho (*Red*) de $0,6$ a $0,7 \mu\text{m}$.

- ii. Infravermelho próximo - 0,7 a 1,3 μm . Também conhecido como infravermelho fotográfico. É importante pela sua capacidade de detetar vegetação e concentrações de humidade.
- iii. Infravermelho médio - 1,3 a 8 μm . É nestes comprimentos de onda que se mesclam os processos de reflexão da luz solar e de emissão da superfície terrestre. Muito importante para estimar o conteúdo de humidade da vegetação e deteção de focos de altas temperaturas.
- iv. Infravermelho distante ou térmico - 8 a 14 μm . Inclui a porção emissiva do espectro terrestre onde se deteta o calor.
- v. Micro-ondas - a partir de 1 cm. O seu uso é muito interessante por ser uma energia bastante transparente a cobertura de nuvens.

2.2.2 Características dos sensores

Entre as várias formas de classificar os sensores remotos, a mais utilizada, tem em conta a capacidade do sensor receber energia. Desta forma, fala-se geralmente em dois tipos de sensores: os ativos - quando estes são capazes de emitir a sua própria fonte de energia; os passivos - quando os sensores se limitam a receber energia de uma fonte exterior a estes (Moreira 2007).

As características de um sensor implicam geralmente quatro domínios de resolução, sendo esses: a (i) resolução espectral, (ii) resolução espacial, (iii) resolução temporal e (iv) resolução radiométrica (Crosta 1993).

i. Resolução Espectral

Os princípios da deteção remota baseiam-se na premissa de que os alvos na superfície terrestre têm diferentes comportamentos espectrais, ou seja, cada alvo reflete a energia de maneira diferente.

Este tipo de resolução indica o número e largura dos intervalos do espectro eletromagnético em que é feita a aquisição de imagens pelo sensor. Quanto mais estreitos e numerosos os intervalos, maior é a resolução espectral, sendo assim mais fácil distinguir objetos registados nas imagens. Desta forma um sensor será tanto mais idóneo, quantas mais bandas espectrais possuir, uma vez que facilita a caracterização espectral dos diferentes objetos (Moreira 2007).

ii. Resolução Espacial

Representa a capacidade que o sensor tem em distinguir objetos na superfície terrestre: quanto menor o objeto possível de ser identificado, maior a resolução espacial.

Esta capacidade baseia-se no tamanho do pixel. Geralmente só objetos maiores que a área do pixel podem ser identificados, embora isso também possa depender da reflectância e do contraste entre objetos próximos. O tamanho do pixel é definido pela LV (largura de varrimento) do sensor, que é a secção angular, geralmente medida em radianos, observada por este num determinado momento.

A resolução espacial de um sensor é muito importante na medida em que quanto maior for, maior será a capacidade do sensor discriminar objetos próximos, dependendo essa de vários

fatores, como sejam a altura orbital, a velocidade de exploração e o número de detetores (Florenzano 2002).

iii. Resolução Temporal

Esta resolução corresponde ao tempo que o satélite demora para voltar a recobrir a área de interesse. O ciclo de cobertura está relacionado com as características orbitais do satélite, como sejam a altura, velocidade e inclinação, assim como do desenho do sensor, principalmente do angulo de observação e abertura (Chuvienco 1995).

iv. Resolução Radiométrica

Corresponde à capacidade que o sensor possui para detetar variações do nível de radiação espectral recebida. A radiância de cada pixel passa por uma codificação digital, obtendo um valor numérico, expresso em bits, denominado de número digital (ND). Este valor é facilmente traduzido para uma intensidade visual ou ainda a um nível de cinza, localizado num intervalo finito (0, K-1), onde K é o número de valores possíveis, denominados de níveis de quantização (Schowengerdt 1983).

O número de níveis de cinza está expresso em bits, ou seja, expresso em função do número de dígitos binários necessários para armazenar, em forma digital, o valor do nível máximo de cinza. O seu valor é sempre em potência de 2, por exemplo 8 bits significam $2^8 = 256$ níveis de cinza. As diferenças são maiores nos níveis 2 e 4 do que nos níveis 256 e 2 048, devido ao facto do olho humano não possuir sensibilidade às mudanças de intensidade acima de 30 níveis de cinza (Crosta 1993).

2.3 O sensor ASTER (Advanced Spaceborne Thermal and Reflection Radiometer)

Atualmente é possível encontrar diversos tipos de satélites de observação da Terra. De acordo com o fim a que se propõe, cada tipo de satélite tem características que influenciam o tipo de sensor a bordo, originando diferentes imagens de satélite (Chuvienco 1995).

Uma imagem de satélite não é mais do que um conjunto de matrizes de valores numéricos, que correspondem aos níveis radiométricos registados pelo sensor em cada uma das bandas espectrais (Moreira 2007).

O Terra é o primeiro de uma série de satélites multi-instrumentos formando o Sistema de Observação da Terra (Earth Observing System - EOS). O EOS engloba componentes de pesquisa e sistema de dados como suporte para uma série temporal de observações globais na superfície terrestre, biosfera, atmosfera e oceanos, por satélites com órbita-polar e baixa inclinação, sendo capaz de fornecer uma compreensão da Terra como um sistema integrado. O satélite Terra efetua uma órbita síncrona-solar, 30 minutos atrás do satélite Landsat ETM+, fazendo medidas da superfície às 10h e 30 minutos da manhã, hora solar local, regressando à mesma órbita com frequência de 16 dias. Viaja a uma altitude média de 705 quilómetros, apresenta parâmetros de órbita iguais ao Landsat 7, com exceção da hora local.

Por dia, adquirem-se 650 cenas, as quais são processadas a nível L1A -sem aplicação de correção geométrica e radiométrica e destas, 150 são processadas a nível L1B - com aplicação de

correções. As cenas são transferidas para os arquivos EOSDIS (Earth Observing System Data and Information System) e EDCDAAC (Eros Data Center Distributed Active Archive Center) para arquivo, distribuição e processamento. Todos estes produtos são armazenados no formato HDF (Hierarchical Data Format).

De acordo com Abram *et al.* o ASTER é um sensor multiespectral que foi lançado em dezembro de 1999. Este sensor gera imagens de média resolução espectral e espacial, registrando dados em vários intervalos do espectro eletromagnético: 3 bandas na região do VIF (Visível e Infravermelho Próximo); 6 bandas na região do IM (Infravermelho Médio) e 5 bandas na região do IT (Infravermelho Térmico) (Figura 6). O subsistema VIF tem ainda um telescópio adicional na banda do infravermelho próximo que fornece visão estereoscópica, já que este apresenta diferente ângulo de visão (*backward*) em relação a uma imagem em Nadir. A resolução espacial varia com o comprimento de onda e corresponde aos diferentes subsistemas. Cada cena ASTER tem dimensão de 60 por 60 quilômetros.




Figura 6 - Região espectral do sensor ASTER (Abrams *et al.* 1999).

Cada subsistema opera numa diferente região espectral tendo os seus próprios telescópios. O subsistema VIF apresenta três bandas com resolução espacial de 15 metros, e um telescópio adicional com capacidade estereoscópica; o IM conta com 6 bandas em resolução espacial de 30 metros; e o IT tem 5 bandas com resolução espacial de 90 metros. As características dos subsistemas são mostradas na tabela 1. É de realçar que desde Maio de 2007 que não se têm imagens ASTER no subsistema IM devido a altas temperaturas do detetor, o que condiciona estudos a partir dessa data.

Tabela 1 - Características dos subsistemas ASTER (adaptado de Abrams *et al.* 1999).

Subsistema	Banda	Resolução Espectral (μm)	Comprimento de onda médio (μm)	Resolução Espacial (m)	Resolução Radiométrica (bits)
VIF	1	0,52 - 0,60	0,556	15	8
	2	0,63 - 0,69	0,661		
	3N	0,78 - 0,86	0,807		
	3B	0,78 - 0,86	0,804		
IM	4	1,60 - 1,70	1,656	30	8
	5	2,145 - 2,185	2,167		
	6	2,185 - 2,225	2,209		
	7	2,235 - 2,285	2,262		
	8	2,295 - 2,365	2,336		
	9	2,360 - 2,430	2,400		
IT	10	8,125 - 8,475	8,291	90	12
	11	8,475 - 8,825	8,634		
	12	8,925 - 9,275	9,075		
	13	10,25 - 10,95	10,657		
	14	10,95 - 11,65	11,318		

2.4 Sistemas de classificação de imagens digitais

A classificação de imagens é geralmente definida como o processo de extrair diferentes classes ou temas, a partir de dados registados por sensores remotos (Xie *et al.* 2008). Para isso utilizam-se algoritmos estatísticos de classificação (classificadores). Dependendo do algoritmo utilizado no procedimento, a classificação é dita supervisionada ou não-supervisionada (Moreira 2007).

A classificação supervisionada parte de um certo conhecimento da zona de estudo, adquirida por experiência própria e por trabalhos de campo, embora autores como Rocha (2002) também assinalem como importante a prévia interpretação de fotografias aéreas, assim como de cartas temáticas pré-existentes. A classificação supervisionada engloba três fases distintas: (i) definição da legenda e marcação das áreas de treino; (ii) classificação; (iii) apresentação e avaliação dos resultados.

Na fase de definição da legenda (i), o analista, tendo em conta o estudo a realizar, define a legenda que melhor se enquadre e adapte aos resultados a atingir, podendo por exemplo basear-se em legendas da cartografia oficial já pré-definidas para a área de estudo (ex. Carta de Ocupação do Solo e Corine Land Cover), marcando posteriormente áreas que vão permitir ao classificador assimilar as distintas categorias da legenda, para classificação. Na fase de classificação (ii), cada pixel é atribuído à classe de ocupação do solo com a qual apresenta maior similaridade. Na última fase, de apresentação e avaliação de resultados (iii), é gerada uma

imagem final (mapa temático), que poderá ser ou não representativo do território classificado de acordo com a análise da respetiva matriz de confusão e posterior determinação de índices de avaliação da exatidão da classificação gerada (Chuvieco 1995).

2.4.1 Áreas de treino

Para que uma imagem de satélite possa ser interpretada convenientemente, é necessário que exista um conhecimento prévio, que nos permita identificar cada uma das categorias de interesse, como sejam a tonalidade, a textura ou o tamanho, levando deste modo a que se reúnam um conjunto de estatísticas que descrevam o comportamento espectral de cada classe.

Existem várias formas de registar áreas de treino: (i) recolhendo informação no terreno; (ii) delimitando áreas de treino sobre a imagem visualizada no monitor; (iii) criando áreas de treino por crescimento de regiões previamente identificadas na imagem (IBGE 2001).

Independentemente da forma como são delimitadas as áreas de treino, o número mínimo de pixels a considerar por classe a digitalizar pode ser obtido multiplicando por dez vezes o número de bandas da imagem a utilizar. Por exemplo, se for utilizada uma imagem Landsat TM com sete bandas, deverão marcar-se pelo menos 70 pixels por cada classe (Eastman 2003).

Na marcação de áreas de treino, é bastante importante a marcação destas cobrindo toda a imagem, aumentando assim a probabilidade dos dados de treino serem representativos de toda a variabilidade inerente às classes de ocupação do solo presentes na legenda (Moreira 2007).

2.4.2 Medidas de separabilidade espectral

Após a marcação de todas as áreas de treino é bastante importante realizar um estudo de separabilidade espectral entre as classes da legenda. Os estudos de separabilidade espectral consistem na aplicação de técnicas que permitem averiguar se as assinaturas espectrais de diferentes classes são ou não estatisticamente diferenciáveis. Quando a análise espectral determina que as assinaturas de duas ou mais classes não são discrimináveis, então é muito provável que, independentemente do classificador utilizado, essas classes não sejam corretamente classificadas. Podemos assim, através de um conjunto de amostras representativas das diferentes classes, ter uma ideia *a priori* do tipo de resultados que se irão obter. Desta forma, os estudos de separabilidade podem dar um excelente contributo para a definição de uma nomenclatura adequada às imagens que se pretendem classificar (Chuvieco 1995).

A Divergência Transformada (DT) é uma medida de separabilidade de um par de distribuições de probabilidade. As equações seguintes determinam a divergência transformada que é baseada na matriz de covariância das amostras recolhidas para cada classe ao nível do pixel (Richards *et al.* 2006).

$$D_{ij} = \frac{1}{2tr} (c_i - c_j)(c_i^{-1} - c_j^{-1}) + \frac{1}{2tr} (c_i^{-1} - c_j^{-1}) (\mu_i - \mu_j)(\mu_i - \mu_j)^T \quad (1)$$

onde:

D_{ij} - divergência para um par de distribuição (assinaturas);

tr - somatório da diagonal principal;

c_i - matriz de covariância para assinatura i ;

c_j - matriz de covariância para assinatura j ;

T - matriz transposta.

A divergência transformada é dada pela seguinte equação:

$$TD_{ij} = 2000 (1 - \exp^{-D_{ij}/8}) \quad (2)$$

De acordo com Jensen (1996), a divergência transformada estima um peso exponencialmente decrescente para aumentar as distâncias entre as classes. A escala dos valores de divergência transformada varia de 0 a 2. Quanto maior o valor, maior será a separabilidade entre as classes. Para fins de comparação, a divergência transformada pode ser normalizada para uma faixa de variação determinada. Segundo o mesmo autor, a interpretação dos resultados sugere, como regra geral, que amostras bem separadas apresentam valores superiores a 1,9, a separabilidade é considerada razoável quando os valores situam-se entre 1,7 e 1,9 e má com valores abaixo de 1,7. Na faixa abaixo de 1,7, a resposta espectral das classes é muito semelhante e o algoritmo de classificação provavelmente não fará uma distinção eficiente entre elas.

2.4.3 Classificação

A classificação automática tem a finalidade de associar a cada pixel da imagem um uma classe de uso ou ocupação do solo, sendo esta implementada com base nas diferenças de comportamento dos materiais ao longo do espectro eletromagnético, podendo ser supervisionada (relacionando classes das áreas da imagem com sítios de treino representando a classe a classificar) ou não supervisionada (agrupamento dos pixels segundo as suas características espectrais). Uma imagem classificada é um mapa temático digital, que pode ser posteriormente incorporado num sistema de informação geográfica (IBGE 2001).

Nos seguintes sub-capítulos descrevem-se os classificadores utilizados para a elaboração do trabalho, com as suas principais características.

2.4.3.1 Classificador da Máxima Verosimilhança

A classificação da máxima verosimilhança (MV) é a classificação supervisionada mais aplicada no tratamento de dados adquiridos por satélites. Este método é baseado no princípio de que a classificação errada de um pixel particular não tem mais significado do que a classificação errada de qualquer outro pixel na imagem (Richards e Jia 2006).

Neste método de classificação, a partir dos dados das amostras de treino de uma classe é estimada a distribuição de probabilidade de encontrar os valores de um pixel dessa classe numa

distribuição normal (gaussiana). Com este pressuposto, a distribuição de cada classe pode ser descrita pela média e covariância, podendo-se calcular a probabilidade de determinado pixel pertencer a cada uma das classes definidos na fase de treino. A regra de decisão da máxima verosimilhança é a seguinte:

$$\text{Se } P_c \geq P_i, \forall i \neq c \text{ então} \quad (3)$$

classe (x) = c

onde:

i = m classes definidas na fase de treino, ou seja: i = 1,2,...,m:

c = classe.

A probabilidade de um determinado pixel x pertencer à classe c é determinada da seguinte forma:

$$P_c = \{-0,5 \log_e [\det(V_c)]\} - [0,5 (X-M_c)^T V_c^{-1} (X-M_c)] \quad (4)$$

onde:

V_c = matriz de covariância dos dados da amostra da classe c;

M_c = vetor da média dos dados da amostra da classe c.

Como ilustrado na figura 7, podem existir pixels com baixa probabilidade de entrar em qualquer uma das classes previstas e para não serem classificados erradamente numa das classes pode ser adotado um limite mínimo de aceitação de um pixel na classe, chamado de limiar (*threshold*), onde abaixo dessa probabilidade o pixel em questão ficará sem classe (Figura 8).

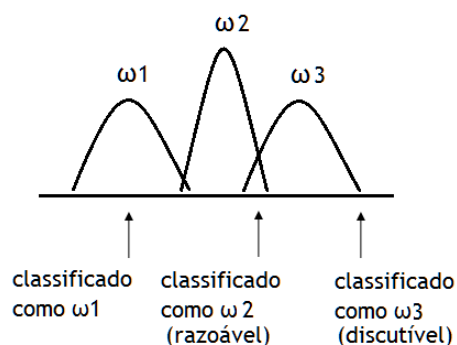


Figura 7 - Distribuição gaussiana das classes hipotéticas ω1, ω 2 e ω 3 (adaptado de Richards e Jia 2006).




Figura 8 - Distribuição gaussiana das classes hipotéticas ω1, ω 2 e ω 3 (adaptado de Richards e Jia 2006).

A máxima verosimilhança apresenta como desvantagem o facto de partir do pressuposto que todas as amostras têm distribuição normal, o que nem sempre se verifica.

2.4.3.2 Classificador de Máquinas de Vetores de Suporte

O classificador de máquinas de vetores de suporte (MVS) é uma classificação supervisionada, sendo baseada numa técnica de aprendizagem da máquina, e fundamentada nos princípios da minimização do risco estrutural (*Structural Risk Minimization*). Procura minimizar o erro em relação ao conjunto de treino (risco empírico), assim como o erro em relação ao conjunto de teste, isto é, conjunto de amostras não empregues no treino do classificador (risco na generalização) (Yang 2011).

O objetivo das MVS consiste em obter um equilíbrio entre esses erros, minimizando o excesso de ajustes com respeito às amostras de treino (*overfitting*) e aumentando consequentemente a capacidade de generalização (Vapnik 1999).

O processo de treino consiste em treinar o classificador de forma que este aprenda um mapeamento x a y por meio de exemplos (classes) de treino $\{x_i, y_i\}$ de forma que a máquina seja capaz de classificar um exemplo (x, y) ainda não visto que siga a mesma distribuição de probabilidade (P) dos exemplos de treino (Yang 2011).

A ideia básica das MVS para classificação de padrões é o de construir um hiperplano ótimo usando um subconjunto da amostra de treino servindo de vetores de suporte e de maximização da margem de separação (Vapnik 1999).

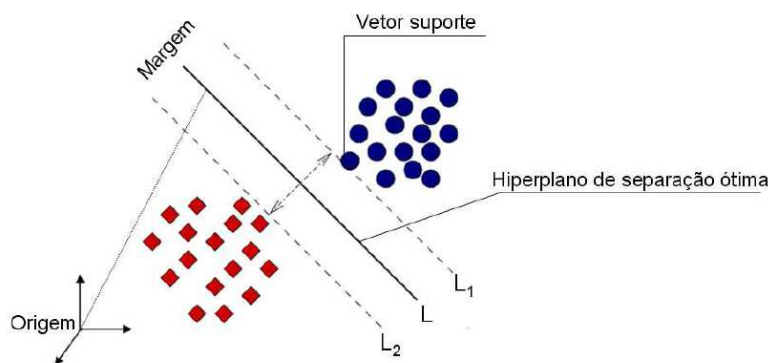


Figura 9 - Esquema de classificação por MVS (adaptado de Huang *et al.* 2002).

O algoritmo hiperplano ótimo original era um classificador linear. Boser *et al.* (1992) introduziram um método para criar classificadores não-lineares utilizando funções *kernel*¹ não lineares para substituir cada produto interior no algoritmo hiperplano ótimo. Para classificação de padrões, o mapeamento não linear transforma cada vetor de um espaço de entrada para um espaço de características alto dimensional, e o uso de um *kernel* permite que o algoritmo se ajuste ao máximo hiperplano no espaço de características transformadas (Yang 2011). Um *kernel* que possa ser utilizado numa MVS deve ter em conta o teorema de Mercer, o qual determina se um *kernel* candidato é realmente um *kernel* produto interno (Haykin 1999).

¹ Uma função *kernel* é utilizada com a finalidade de corrigir as não-linearidades dos dados através de uma transformação dos mesmos num espaço de grande dimensionalidade. Desta forma, torna-se possível realizar a análise linear dos dados naquele espaço (Nielsen e Canty, 2009).

Os *kernel* geralmente utilizados são o *linear*, *polynomial*, *radial basis function* e *sigmoid*, e as suas representações matemáticas, segundo Haykin (1999) são as seguintes:

- i. *Linear* - $K(X, X_i) = X^T X_i$
- ii. *Polynomial* - $K(X, X_i) = (\gamma X^T X_i + r)^p, \gamma > 0$
- iii. *Radial basis function* - $K(X, X_i) = \exp(-\gamma ||X - X_i ||^2), \gamma > 0$
- iv. *Sigmoid* - $K(X, X_i) = \tanh(\gamma X^T X_i + r)$

onde X representa um vetor desenhado a partir do espaço de entrada; X_i é um vetor desenhado a partir das características do espaço; γ é o termo de *gamma* para cada tipo de *kernel*, exceto no *linear*; p é o grau de *polynomial* e r é o termo *bias* para *polynomial* e *sigmoid kernels*. É de notar que os três primeiros *kernels* satisfazem sempre o teorema de Mercer, sendo que o último apenas o satisfaz em alguns valores de γ e r .

As MVS apresentam vantagens relativamente a outros classificadores convencionais, especialmente quando o número de amostras de treino é pequeno e a dimensionalidade dos dados é grande, devido ao facto de que os classificadores convencionais não terem mecanismos para maximizar a margem (distância entre os dois hiperplanos extremos). A maximização da margem permite aumentar a capacidade de generalização do classificador (Abe 2005).

2.4.3.3 Redes Neurais Artificiais

Uma rede neuronal artificial (RNA) é uma estrutura matemática não-linear capaz de representar processos complexos não-lineares, sendo um processo de classificação supervisionada. Pode ser utilizada para relacionar as entradas e saídas de qualquer sistema. Modelos de redes neuronais têm sido utilizados com sucesso numa ampla variedade de áreas, incluindo finanças, medicina, física, engenharia, geologia, hidrologia, ecologia e geografia. A principal vantagem desta abordagem em relação aos métodos tradicionais é que esta não necessita de informação sobre processos complexos para ser efetuada com sucesso (Sudheer *et al.* 2010).

As vantagens das redes prendem-se com o facto de estas serem um método não paramétrico e como tal não terem uma distribuição associada (Foody 2000), possuírem elevada tolerância a dados com ruído (Qiu e Jensen 2004) possuírem uma arquitetura muito flexível que pode ser facilmente modificada para aumentar a sua performance (Han *et al.* 2002), apresentarem boa capacidade para classificar padrões para os quais não foram treinadas (Foody 2000, Qiu e Jensen 2004) e finalmente, por integrarem facilmente dados auxiliares (Han *et al.* 2002).

As RNA pretendem simular o funcionamento do cérebro humano e tal como este utilizam neurónios e conexões entre eles para processar a informação. Cada neurónio recebe informação de neurónios vizinhos e envia-a para outros neurónios através das conexões. Estas conexões têm a designação de pesos ou ponderações. O processo decorre da seguinte maneira: a informação é

enviada para os neurónios com base nos valores de *input* (pesos de receção). O *input* é processado por uma função de combinação que soma todos os valores ponderados recebidos. O valor resultante é comparado com um valor limiar, o *bias*, o qual é subtraído a essa soma ponderada aplicando-se de seguida uma função de ativação. O *bias* é o valor limiar a partir do qual o neurónio é inibido. Da aplicação da função de ativação (função sigmoideal, linear ou outra) resulta um valor que será propagado para os neurónios da camada seguinte e assim sucessivamente (Loureiro 2008).

A capacidade de aprendizagem e de generalização constitui um dos principais motivos de utilização das redes neuronais na resolução de problemas (Erbek *et al.* 2004).

A rede tem a capacidade de aprender por indução, a partir de um conjunto de dados de treino. Durante o processo de aprendizagem, os pesos sinápticos são ajustados de acordo com procedimentos matemáticos específicos, tais como: otimização discreta, minimização de erros, *clusterização* de vetores, entre outros, que determinam como será realizado o treino, ou da rede neuronal. No final deste processo, o conhecimento adquirido do conjunto de treino será representado pelo conjunto de pesos da rede.

A capacidade de generalização do conhecimento adquirido, é fundamental de forma a que a rede possa responder adequadamente a padrões de entrada com os quais não foi treinada (Loureiro 2008).

2.4.4 Pós-processamento

Os métodos utilizados para estimar a exatidão dos mapas obtidos têm como ponto de partida a construção de uma matriz de confusão (ou erro). Esta matriz apresenta a distribuição da percentagem de pixéis classificados de forma correta e errónea (Congalton 1991). Segundo Moreira (2007), o uso da matriz de confusão é útil em pelo menos três objetivos: i. oferece dados que permitem o ajuste das áreas das classes obtidas por algum tipo de classificação; ii. possibilita o cálculo de parâmetros de exatidão geral da classificação; iii. permite a identificação de erros específicos que afetam cada uma das categorias.

A matriz de confusão é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma categoria da legenda - inferida por um classificador (ou regra de decisão), em comparação com a categoria atual verificada no campo (Congalton 1991).

Normalmente, ao longo das colunas representa-se o conjunto de dados de referência, que é comparado com os dados do produto da classificação, sendo estes representados ao longo das linhas. A tabela 2 exemplifica a representação de uma matriz de confusão. Os elementos da diagonal principal (a negrito) indicam o nível de acerto (ou concordância) entre os dois conjuntos de dados e n é o número total de amostras recolhidas (Chuvieco 1995).

Tabela 2 - Representação de uma matriz de confusão.

Classificação	Dados de Referência			Total nas linhas X_{i+}
	1	2	C	
1	X_{11}	X_{12}	X_{1c}	X_{1+}
2	X_{21}	X_{22}	X_{2c}	X_{2+}
C	X_{31}	X_{32}	X_{3c}	X_{c+}
Total nas colunas X_{+i}	X_{+1}	X_{+2}	X_{+c}	n

2.4.4.1 Medidas globais de fiabilidade

Os resultados da matriz de confusão permitem calcular os seguintes índices:

- i. exatidão global (EG);
- ii. exatidão do produtor (EP) das classes;
- iii. exatidão do utilizador (EU) das classes;
- iv. índice Kappa (K), da globalidade da legenda e por classe individual.

A exatidão global permite calcular a viabilidade global do mapa, relacionando os elementos da diagonal com o total de amostras recolhidas, dado pela seguinte fórmula (Watzlawick *et al.* 2003):

$$EG = \frac{\sum X_i}{N} * 100 \quad (5)$$

onde:

X_i = elementos na diagonal

N = total de amostras

A distribuição da exatidão ao longo das categorias individuais não é apresentada na exatidão global. Entretanto a exatidão de uma categoria individual é obtida através da exatidão do produtor na classe e exatidão do utilizador na classe.

Segundo Congalton e Green (1999) a exatidão de produtor indica a probabilidade da amostra ser classificada corretamente, sendo realmente uma medida de erro de omissão, e a exatidão do utilizador indica a probabilidade que um pixel classificado na imagem tem de representar aquela categoria no campo, calculada pelas seguintes fórmulas:

Exatidão do Produtor

$$EP_j = \frac{X_{jj}}{n_{i+}} \quad (6)$$

Exatidão do Utilizador

$$EU_j = \frac{X_{jj}}{n_{+j}} \quad (7)$$

onde:

X_{jj} = número de observações da amostra de validação classificada na classe j do mapa e que corresponde à classe j na informação de referência;

n_{i+} = total de observações da amostra de validação classificadas no mapa com a classe i;

n_{+j} = total de observações da amostra de validação pertencentes à classe j.

A análise do índice Kappa é uma técnica multivariada discreta usada na avaliação da exatidão temática, desenvolvida por Cohen em 1960. Segundo Vieira (2000), o coeficiente Kappa é uma medida da concordância real (indicado pelos elementos diagonais da matriz de confusão), ou seja, é uma medida do quanto a classificação está de acordo com os dados de referência. Além do coeficiente Kappa, pode ser proveitoso usar o coeficiente Kappa condicional (KC) para calcular o acerto dentro de uma categoria individual.

Índice Kappa

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (8)$$

Índice Kappa condicional

$$Kc = \frac{N x_{ii} - x_{i+} x_{+i}}{N x_{i+} - x_{i+} x_{+i}} \quad (9)$$

onde:

- N = número total de observações;
- r = numero de linhas da matriz de confusão;
- x_{ii} = observações na linha i e coluna i;
- x_{i+} = total marginal da linha i;
- x_{+i} = total marginal da coluna i.

Embora o índice Kappa seja muito utilizado na avaliação da exatidão temática, não existe uma fundamentação teórica para recomendar os níveis aceites numa classificação. No entanto, geralmente são utilizados e aceites pela comunidade científica, a classificação desenvolvida por Landis e Koch em 1977 (elaborada para analisar resultados da análise de diagnósticos clínicos), que está definida na tabela 3.

Tabela 3 - Qualidade da classificação dos valores Kappa (adaptado de Landis e Koch 1977).

Valor de Kappa	Qualidade do mapa temático
<0,00	Péssima
0,00 - 0,20	Má
0,20 - 0,40	Razoável
0,40 - 0,60	Boa
0,60 - 0,80	Muito Boa
0,80 - 1,00	Excelente

Congalton (1991) defende que o uso do coeficiente Kappa é satisfatório na avaliação da exatidão de uma classificação temática, pelo facto de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na classificação, ao contrário, por exemplo, da exatidão global, que utiliza somente os elementos diagonais (concordância real).

2.5 Invasões biológicas e espécies exóticas invasoras

A propagação e dispersão de espécies exóticas invasoras têm vindo a impor desafios complexos que ameaçam tanto a riqueza natural da Terra como o bem-estar do ser humano. Segundo o International Union for the Conservation of Nature (IUCN 2000), as espécies invasoras de origem exótica - plantas, animais e micro-organismos - são uma das principais causas atuais de perda de biodiversidade, só comparável à alteração dos habitats por ação humana direta.

Pelo perigo que constituem para a biodiversidade dos territórios, as plantas invasoras não devem ser utilizadas nem cultivadas. Em Portugal o Decreto-Lei nº 565/99 regula a introdução e utilização de fauna e flora não indígena, estando aí listadas cerca de 400 espécies, sendo 20 destas plantas invasoras. Outros autores, como Marchante *et al.* (2005), consideram que além das espécies listadas no Decreto-Lei, outras 150 poderão ser consideradas como plantas exóticas em Portugal.

2.5.1 Invasões biológicas

Uma invasão biológica ocorre quando um organismo, de qualquer tipo, se estabelece num local para além da sua área de distribuição (Williamson 1996), ou seja, quando uma espécie coloniza e persiste numa área onde até então não havia habitado (Shigesada e Kawasaki 1997).

Segundo Heywood (1989) são invasoras as plantas que entram num território onde nunca antes haviam ocorrido, sendo estas geralmente de origem exótica proveniente de outros continentes, instalando-se com sucesso nas comunidades vegetais nativas, invadindo-as e desalojando a vegetação nativa. Outros autores, como Cronk e Fuller (2001) definem plantas invasoras como plantas alienígenas, dispersando-se naturalmente, sem intervenção humana direta, em habitats naturais e semi-naturais, produzindo uma alteração significativa na sua composição, estrutura ou nos processos ecológicos.

Presentemente, as definições da IUCN (2000) consideram que o termo invasor só se deve aplicar aquelas espécies que têm um impacto negativo na biodiversidade, constituindo a base para as definições utilizadas pela Convenção para a Diversidade Biológica.

2.5.2 Etapas do processo de invasão

O processo de invasão varia de acordo com múltiplos fatores, nomeadamente as características da espécie invasora, as características do ecossistema invadido, e as interações com as espécies nativas (Lockwood *et al.* 2006). A maioria das invasões ocorre em habitats afetados pelas atividades humanas, particularmente, naqueles que são sujeitos a distúrbios acentuados, mas isso pode apenas refletir o facto de as espécies serem mais facilmente transportadas para esses locais (Williamson 1996).

Uma invasão biológica é um processo dinâmico e não um acontecimento ou episódio localizado, ao longo do qual a população invasora atravessará várias fases (Deacon 1991) (Figura 10).

Após a introdução, muitas espécies apresentam uma fase de latência relativamente longa, durante a qual o seu efetivo se mantém mais ou menos constante (Le Floch 1991). Quando isso

acontece diz-se que a espécie está naturalizada. A regra geral é a de que cerca de 10% das espécies introduzidas se tornarão naturalizadas, enquanto que 10% dessas se tornarão nocivas (Smith *et al.* 1999). Este valor serve de orientação geral, sendo comum que estes valores oscilem entre 5-20% (Williamson 1996). Uma vez naturalizada, a espécie pode entrar numa fase de expansão (Ribera e Boudouresque 1995): i. expansão ecológica - ocupação de diferentes biótopos; ii. expansão geográfica - aumento da sua área de distribuição.

A expansão ecológica é geralmente facilitada por algum acontecimento/fenómeno (facilitação), podendo ser segundo Naylor (2000) perturbações de origem natural, por fogos controlados ou construção de infraestruturas. A “facilitação” pode ser ainda devido à introdução de um agente dispersor ou polinizador, ou à ausência de pestes e doenças (Cronck e Fuller 1995).

O aumento de distribuição de espécies invasoras depende da sua taxa de crescimento e reprodução, da eficiência dos seus mecanismos de dispersão e das características do habitat invadido. Na última etapa de um processo de invasão, as espécies invasoras passam a interagir com as espécies animais e vegetais que as rodeiam e, finalmente podem estabilizar (Marchante 2001).

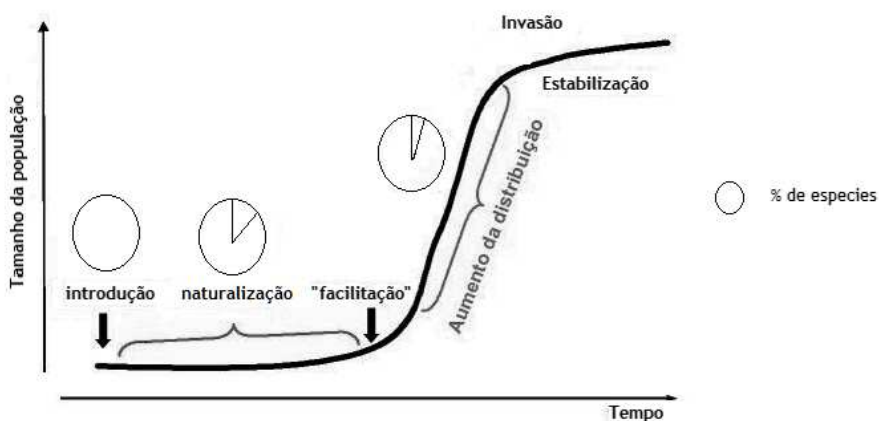


Figura 10 - Principais etapas de um processo de invasão (adaptado de Marchante 2001).

2.5.3 Impacte das invasões biológicas

Estudos rigorosos acerca do impacte das invasoras têm sido dificultados porque, em geral, a investigação é desencadeada apenas depois da ocorrência de uma expansão considerável da invasora, e apenas para aquelas espécies que aparentam já causar algum impacte (Parker *et al.* 1999). No entanto têm sido apontados impactes como a perda de biodiversidade do planeta e a intensificação das alterações globais. Entre outras consequências podem-se incluir:

Impactes ecológicos

- i. Impactes no ciclo dos nutrientes - a substituição das espécies nativas por invasoras conduz a um aumento acentuado das taxas de libertação de nutrientes de folhas em decomposição (as invasoras têm geralmente elevada taxa de crescimento de folhagem e nutrientes nas folhas), criando um reforço positivo da invasão por espécies que prosperam em solos enriquecidos (Parker *et al.* 1999);

- ii. Impactes na hidrologia - segundo Zhang *et al.* (1999) as invasoras extraem um maior volume de água do solo e as suas copas interceptam a precipitação, aumentando as perdas por evaporação;
- iii. Impactes em processos geomorfológicos - as espécies vegetais invasoras podem alterar a estabilidade do substrato dos solos ou modificando a composição do sub-bosque ou da folhada, o que por sua vez altera os processos erosivos (Mack e D'Antonio 1998);
- iv. Impactes no regime do fogo - um dos efeitos das plantas invasoras sobre os ecossistemas nativos é a alteração das propriedades dos combustíveis vegetais, modificando características do regime de fogo, tais como frequência, intensidade, extensão, tipo e sazonalidade do fogo (Brooks *et al.* 2004);
- v. Outros impactes ecológicos - impactes sobre a fauna nativa, alteração das cadeias alimentares e extinção de espécies (Marchante 2001).

Impactes económicos

- vi. Impactes na agricultura e silvicultura - as perdas na agricultura, fazem com que as colheitas sejam menores (segundo Pimentel (2005) em cerca de 12%), e que se aumentem os custos de produção devido ao controlo que é efetuado nas invasoras. As espécies exóticas invasoras produzem também elevados prejuízos no sector florestal, quer diretos, quer devidos ao custo das ações de controlo;
- vii. Outros impactes socioeconómicos - outros impactos incluem a saúde humana, o turismo e recreio, e o património arquitetónico e arqueológico (Fernandes 2008).

2.6 Situação da *Acacia dealbata* em Portugal Continental

A *Acacia dealbata* Link (mimosa) é uma espécie da família *Leguminosae*, originária da Tasmânia - Austrália (Marchante *et al.* 2005). As suas principais características morfológicas estão descritas na tabela seguinte:

Tabela 4 - Caracterização morfológica da *Acacia dealbata* (adaptado de Fernandes 2008).

Atributo	Descrição
Fisionomia	Arbusto ou árvore de pequeno porte, geralmente com 12-15 m de altura, podendo atingir 30 m, com folhagem perenifólia, não possuindo espinhos.
Tronco e Ramos	Tronco principal ereto; ramos ligeiramente angulosos, estriados, pruinosos e pubescentes, formando copa cónica ou arredondada.
Casca	Lisa, de cor verde glauca nos ramos jovens, posteriormente pardo-acinzentada ou acastanhada, profundamente enrugada quando idosa.
Folhas	Folhas com uma cor verde-glaucosa a amarelado; folhas bipinuladas com 20-25 pares de folíolos, com cerca de 5 milímetros cada; glândulas numerosas, ocorre de forma regular ao longo da ráquis, no ponto de inserção das pínulas.
Inflorescências	Glomérulos globosos de 5-6 cm de diâmetro, pedunculados, com 25-30 minúsculas flores e brácteas interflorais peltadas; glomérulos agrupados em conflorescências racemiformes, axilares, ou conflorescências paniculiformes, terminais ou axilares; pedúnculo com 5-6 cm de comprimento, pubescente; o eixo da conflorescência é frequentemente em zigue-zague.
Flores	Apresentam-se em capítulos reunidos em ráculos ou panículas terminais axilares, amarelo vivo, com 5-6 milímetros de diâmetro e 30-40 flores cada; vagem com 4-10 centímetros de comprimento por 1-1,2 centímetros de largura.
Fruto	<i>Vagem</i> com 5-8 centímetros de comprimento por 0,8-1,2 centímetros de largura, de forma elipsoidal, comprimida, reta ou ligeiramente curva de cor verde-azulada ou pardo-avermelhada; <i>Sementes</i> com 4-5 milímetros por 2,5 milímetros, com formato elipsoidal, de cor parda.

A mimosa é uma espécie de crescimento rápido - de 1 a 1,5 metros ano, adaptado a climas temperados, ventos salgados, ao frio e gelo e temperaturas a rondar os 40°C (May e Attiwill 2003). Cresce preferencialmente em terrenos frescos de vales ou margens de cursos de água, sendo também muito frequente ao longo de vias de comunicação (Marchante *et al.* 2005).

O sistema radicular da mimosa é caracterizado por ter raízes laterais, com capacidade de abrolhamento e de formação de lançamentos aéreos (vergõntes ou rebentões) a certa distância da planta-mãe, podendo-a multiplicar vegetativamente. No solo tem também efeitos alelopáticos, inibindo o crescimento de outras espécies (Fernandes 2008).

É uma espécie fixadora de azoto atmosférico, alterando as concentrações deste no solo, afetando assim espécies autóctones (Reichard 1996).

A maturidade sexual da espécie ocorre geralmente entre os 4-5 anos de idade, com um período de floração na Península Ibérica entre janeiro e março (Paiva 1999), com algumas oscilações pontuais.

O seu elevado potencial invasor advém da elevada produção de sementes, dispersão e longevidade no solo, assim como a estimulação das sementes pelo fogo (característica do clima mediterrânico no Verão), permitindo que áreas recentemente aridas recuperem facilmente os seus povoamentos (Marchante 2001).

A *Acacia dealbata* foi introduzida em Portugal Continental no final do século XIX, surgindo a primeira notícia da sua implantação no território em 1850, na Quinta do Lumiar em Lisboa. Um dos principais motivos de difusão da espécie poderá ter sido dado por Tait em 1886, o qual oferecia pacotes de sementes aos assinantes do Jornal de Horticultura Prática. A mimosa foi também introduzida no Gerês entre 1897-1914 pela Administração Geral das Matas, tendo sido plantados mais de 1200 pés.

A grande propagação da mimosa a partir dessa época foi devido à propaganda de diversas “virtudes” da espécie, quer ornamentais, quer pelos seus produtos: flores de corte, taninos para a indústria de curtumes, madeira de construção e lenhas com elevado poder calorífico. Outro grande fator influenciador da propagação de mimosa teve origem na antiga Junta Autónoma de Estradas, em que esta plantava pés de mimosa nos taludes das estradas para fixação de terras (fenómeno que se comprova atualmente ao longo das estradas “secundárias”), podendo-se dar como exemplo o troço da rodovia IP4, inaugurada em 1987, cujas bermas foram plantadas com *Acacia dealbata* (Fernandes 2008).

O potencial invasor e prejudicial das mimosas (e *Acacia* sp. em geral) foram reconhecidos em legislação publicada em 1937 (Lei n.º 1951 de 9 de março de 1937). Por sua vez o primeiro controlo no território nacional consistiu em dois ensaios efetuados na Serra de Sintra nos anos de 1974-1975 (Costa 1976). Atualmente a mimosa é classificada como invasora pelo Decreto-Lei 565/99 de 21 de Dezembro.

2.7 Detecção remota aplicada à cartografia e monitorização de vegetação exótica invasora

Quase todos os ecossistemas do Planeta têm problemas com espécies exóticas invasoras, sendo estas invasoras um dos maiores problemas para a biodiversidade do Planeta (Pimentel *et al.* 2005).

A deteção remota é um instrumento que possui vantagens documentadas, tais como: dados multiespectrais e hiperespectrais; cobertura multitemporal da superfície terrestre (existem imagens de satélite a partir da década de 70) e uma relação custo-eficácia baixa (Van der Meer *et al.* 2002). Está provado que a deteção remota é uma solução prática para estudar terrenos morfologicamente complexos e diversos tipos de ecossistemas inacessíveis (Joshi *et al.* 2004). Pode fornecer um vasto tipo de sistemas sensores, incluindo fotografia aérea, sensores aéreos multiespectrais, imagens de satélite e baixa e alta resolução espectral e espacial.

Um número crescente de publicações (Figura 11) têm vindo a tratar de aplicações de sistemas de informação geográfica e deteção remota na deteção de espécies exóticas invasoras, nomeadamente na sua distribuição, abundância, cartografia, modelação e fatores que influenciam a sua distribuição.




Figura 11 - Publicações sobre aplicações de SIG e DR no mapeamento de invasoras (adaptado de Joshi *et al.* 2004).

A deteção remota e os sistemas de informação geográfica têm-se afirmado como uma ferramenta útil para a cartografia e monitorização das invasoras, assim como para providenciar dados que permitam prever áreas suscetíveis de invasão por espécies exóticas.

Assim que as espécies exóticas se encontram presentes num território, a deteção remota, em comparação com técnicas de campo, permite a cartografia total do território. Imagens derivadas de locais com invasoras podem fornecer um registo permanente que pode ser a entrada de dados em bases de dados SIG para atividades de controlo. A aquisição e estudo de imagens repetidas sobre o mesmo território permitem estudar tendências de distribuição de invasoras, permitindo um controlo mais eficaz dessas populações. Em contraste, em áreas onde ainda não existem invasoras, a prevenção é a melhor solução para evitar a disseminação de espécies, podendo ser marcados pontos de prevenção em áreas de risco para a monitorização.

Diversos estudos demonstram a aplicabilidade da deteção remota na cartografia de invasoras, em diversos tipos de resolução espacial/espectral, os quais se apresentarão de seguida:

i. Uso de imagens com resoluções espacial e espectral moderadas

Geralmente os satélites de moderada resolução espacial/espectral envolvem dados com uma resolução espacial entre os 10-100 metros e um número de bandas espectrais inferior a vinte (Huang 2009).

Imagens captadas pelo Thematic Mapper (TM)/Enhanced Thematic Mapper Plus (ETM+) do Landsat, Satellite pour l'Observation de la Terre (SPOT) e Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER), têm sido utilizados no mapeamento de espécies exóticas invasoras. Viana e Aranha (2005) utilizaram imagens de Landsat 7 ETM+ e ASTER na deteção de *Acacia dealbata* nos distritos de Guarda, Viseu e Coimbra, através dos classificadores da máxima verosimilhança e distância mínima. Cobbing (2007) utilizou imagens Landsat 7 ETM+ na cartografia de *Acacia sp.* para o programa WFW (Working for Water) utilizando o classificador da máxima verosimilhança. Lawes e Wallace (2008) monitorizaram *Acacia nicolata* em Queensland (Austrália) e sua evolução entre 1989 e 2004 através de Landsat 5 TM. Masocha e Skidmore (2011) cartografaram *Lantana camara* no Zimbábue utilizando classificadores "clássicos" como as RNA e MVS e classificadores híbridos, com recurso a imagens ASTER. Venugopal (1998) utilizou ainda imagens SPOT multitemporais para controlar infestações por *Eichhornia crassipes* utilizando o Índice de Vegetação Normalizado (NDVI - Normalized Difference Vegetation Index).

ii. Uso de imagens com alta e muito alta resolução espacial

As imagens de muito alta resolução espacial caracterizam-se por terem uma resolução espacial na banda do pancromático igual ou inferior a um metro, sendo que em multiespectral essa resolução é geralmente inferior a 5 metros (Pereira e Caetano 2005). Entre os satélites mais utilizados em estudos de detecção remota, podem-se salientar o Quickbird, Orbview e IKONOS que apareceram no final da década de noventa.

O aparecimento deste tipo de imagens potencia a discriminação de elementos na superfície terrestre a grande escala, podendo no entanto ter um efeito negativo na exatidão dos mapas devido à existência de píxéis mistos. Pode-se também apontar como menos positivo neste tipo de imagens, a reduzida resolução espectral (geralmente de quatro bandas espectrais), o que em certos estudos pode ser limitador (Aiplin *et al.* 1997), assim como a elevada variabilidade espectral intra-classe e a presença de sombra (Loureiro 2008).

O uso de imagens de muito alta resolução espacial tem vindo a ser cada vez mais adotada com sucesso no mapeamento de espécies exóticas invasoras. Gil *et al.* (2011) estudaram a eficiência de imagens IKONOS para mapeamento de invasoras em áreas protegidas na Região Autónoma dos Açores, utilizando os classificadores MV, RNA, MVS e da Mínima Distância de Mahalanobis (MDM). Wang (2008) utilizou imagens Quickbird para detecção de *Tamarix* sp. na região de Rio Grande nos Estados Unidos da América, utilizando os classificadores de MV, RNA, MVS, Spectral Angle Mapper (SAM) e Maximum Matching Feature (MMF). Tsai *et al.* (2005) usaram imagens Quickbird para determinar a ocupação da invasora *Leucaena leucocephala* no sudeste de Taiwan, através de análise baseada na textura da imagem. Fuller (2005) mapeou a invasora australiana *Malaleuca quinquenervia* no sul da Flórida, com recurso a imagens IKONOS utilizando a classificação de RNA. Laba *et al.* (2008) aplicaram o classificador MV em imagens Quickbird para estimar a presença de múltiplas invasoras - *Lythrum salicaria*, *Phragmites australis* e *Trapa natans* em diversos meio aquáticos do rio Hudson nos Estados Unidos da América.

iii. Uso de imagens hiperespectrais

Os sensores hiperespectrais caracterizam-se por captar dados em intervalos contíguos e estreitos no espectro eletromagnético, nas regiões do visível, infravermelho próximo e infravermelho médio com intervalos de comprimento de onda extremamente estreitos ($\leq 10\text{nm}$), tendo geralmente um número de bandas espectrais superior a 100 (Huang e Asner 2009). Alguns dos sensores mais utilizados para estudos científicos no âmbito de espécies exóticas invasoras incluem o AVIRIS, CASI e Hyperion.

A utilização de imagens hiperespectrais é atualmente a fonte mais utilizada para estudos de plantas exóticas invasoras (Huang e Asner 2009). Entre estudos que utilizam estas imagens, Lass *et al.* (2005) fizeram uma detecção precoce de *Centaurea maculosa* e *Gypsophila paniculata* com Hyperion utilizando o classificador SAM. Ustin *et al.* (2002) utilizaram imagens AVIRIS para mapeamento de *Mesembryanthemum crystallinum*, *Cortaderia jubata*, *Foeniculum vulgare* e *Arundo donax* na Califórnia - Estados Unidos da América, com recurso aos classificadores supervisionados MV e SAM e não supervisionados K-means e Isodata. Pu *et al.* (2008) com recurso a imagens CASI estudaram modificações de ocupação do solo de *Tamarix* sp. em Lovelock -

Nevada (Estados Unidos da América), utilizando os classificadores de RNA e Análise Discriminante Linear (ADL).

3. Materiais e métodos

Neste capítulo apresentam-se os materiais e métodos necessários à tentativa de concretização do objetivo principal do trabalho de projeto, que passa pela deteção e cartografia da espécie exótica invasora *Acacia dealbata* (mimosa) no distrito de Castelo Branco através do processamento de imagens multiespectrais ASTER (de resolução espacial e espectral moderadas), com recurso aos classificadores da máxima verosimilhança (paramétrico), máquinas de vetores de suporte e redes neuronais artificiais (ambos não-paramétricos).

O procedimento metodológico adotado (Figura 12) foi baseado nas seguintes 6 fases:

1. Definição da área de estudo e compilação de informação geográfica e alfanumérica pertinente;
2. Pré-processamento das imagens ASTER (correções atmosférica e geométrica);
3. Definição da legenda inicial e obtenção de sítios de treino para classificação e validação;
4. Estudo de separabilidade espectral para avaliação da legenda inicial e para proposta de novas legendas derivadas;
5. Classificação das imagens ASTER (para 2 épocas distintas do ano);
6. Pós-processamento para validação dos resultados, através da construção da matriz de confusão e posterior determinação de índices de exatidão.

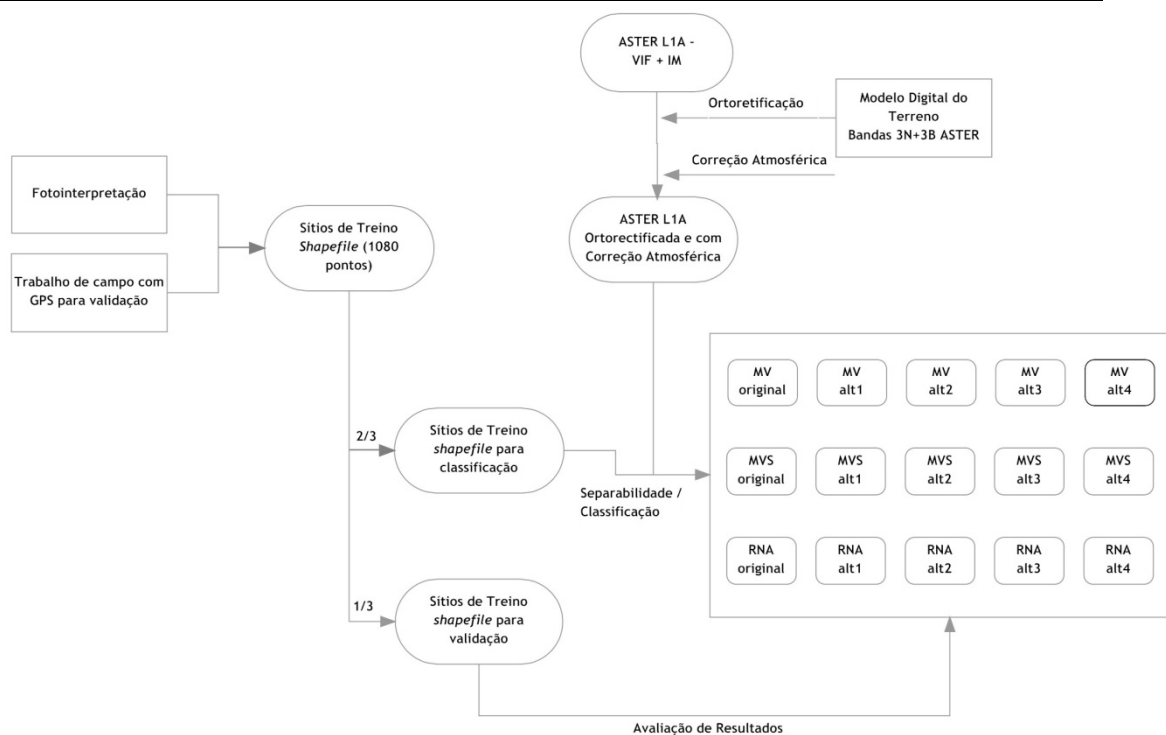


Figura 12 - Esquema metodológico

3.1 Área de estudo

A área de estudo selecionada para a realização do trabalho (Figura 13) consiste numa cena ASTER que abrange parte significativa do distrito de Castelo Branco, com uma área total de 3211 km². O distrito de Castelo Branco foi escolhido para a realização do trabalho de projeto pelo facto de ser uma zona com grande incidência de *Acacia dealbata*, sendo importante o seu mapeamento na região para possível controlo futuro.

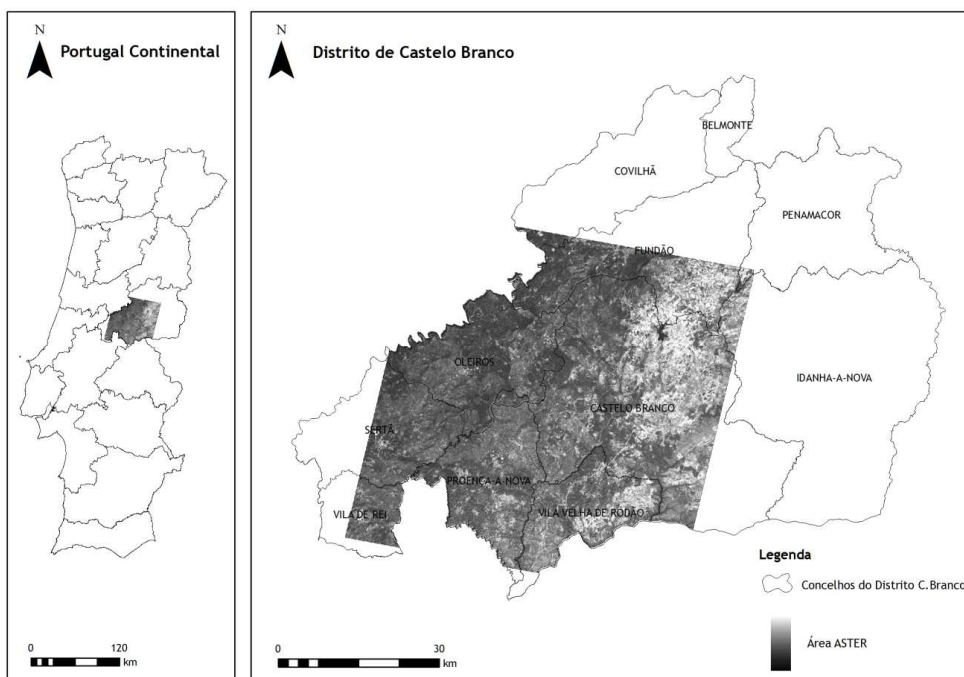


Figura 13 - Localização geográfica da área de estudo.

Para efeitos de caracterização da área de estudo, segundo a carta Corine Land Cover 2006 (EEA/IGP/APA 2009), esta possui maioritariamente “florestas abertas”, seguido de “florestas de resinosas” e “agricultura com espaços naturais e semi-naturais”. São também de realçar as ocupações de “sistemas culturais e parcelares complexos”, de “culturas temporárias de sequeiro” e de “florestas de folhosas” (Figura 14 e Tabela 5).

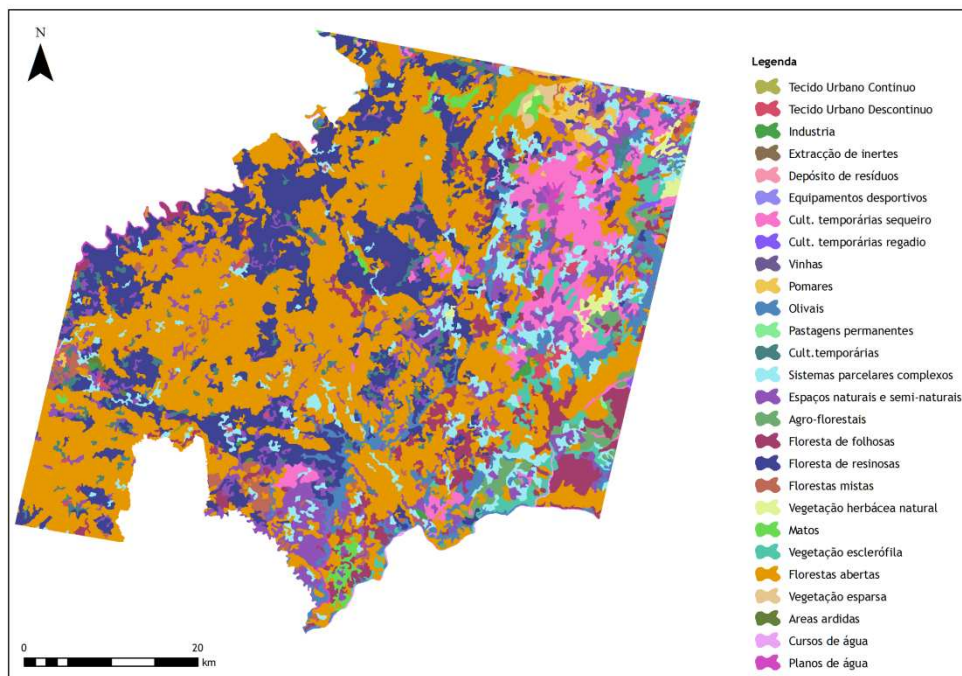


Figura 14 - Corine Land Cover 2006 da área de estudo (EEA/IGP/APA 2009).

Tabela 5 - Área (km²) das principais culturas da área de estudo - Corine Land Cover 2006 (EEA/IGP/APA 2009).

Nomenclatura (Nível 3)	Área (km ²)
Florestas abertas	1372
Florestas de resinosas	547
Agricultura com espaços naturais e semi-naturais	286
Sistemas culturais e parcelares complexos	187
Culturas temporárias de sequeiro	174
Florestas de folhosas	157

3.2 Dados utilizados

Para a elaboração do trabalho foram utilizados três tipos de dados: (i) imagens de satélite; (ii) modelo digital do terreno; (iii) sítios de treino.

3.2.1 Imagens de satélite

Foram escolhidas duas imagens ASTER correspondentes à mesma área. A primeira foi obtida a 25 de agosto de 2005, com uma cobertura de nuvens de 20% e a segunda no dia 24 de março de 2007 com uma cobertura de nuvens de 0%. Foram escolhidas estas duas alturas do ano

de forma a poder comparar a capacidade de cartografar *Acacia dealbata* na respetiva época de floração (março) e ainda na época em que predomina na região um clima bastante seco, podendo acentuar um maior contraste entre diferentes espécies arbóreas (agosto). É de salientar que embora não seja a opção ideal, foram escolhidos dois anos separados porque não havia imagens disponíveis da mesma zona de estudo no mesmo ano, assim como por vezes as imagens tinham uma cobertura de nuvens demasiado elevada para se poder efetuar um trabalho válido.

Ambas as imagens do sensor multiespectral ASTER foram adquiridas no nível L1A, ou seja dados em “bruto”, com apenas correção radiométrica e sem correção geométrica e atmosférica efetuada. O modo multiespectral do sensor possui os subsistemas VIF, IM e IT.

3.2.2 Modelo digital do terreno

Foi elaborado um modelo digital do terreno de forma a ortorectificar as imagens ASTER. Este foi feito a partir das bandas 3N e 3B de cada imagem de satélite.

3.2.3 Sítios de treino

Foram marcados 1080 sítios de treino (120 para cada classe da legenda) num *shapefile* de forma a cobrir toda a área de estudo. A *shapefile* original foi dividida em duas mais pequenas: uma com 810 pontos para classificação da legenda (90 pontos por cada classe da legenda inicial); uma com 270 para validação da legenda (restantes 30 pontos por cada classe da legenda inicial).

Os 1080 sítios de treino foram resultado de fotointerpretação e validação cruzada entre ortofotomapa (de 2005), Carta de Ocupação do Solo 1990, Carta de Ocupação do Solo 2007, Corine Land Cover 2000, Corine Land Cover 2006, Google Earth (várias datas, consoante o mosaico onde se encontra a imagem) e pontos recolhidos por GPS (Tabela 6).

Tabela 6 - Informação geográfica auxiliar utilizada.

Designação	Proprietário	Escala	Unidade mínima cartográfica	Formato
Carta Ocupação do Solo 1990	IGP	1: 25 000	1 ha	Vetorial
Carta de Ocupação do Solo 2007	IGP	1:25 000	1 ha	Vetorial
CORINE Land Cover 2000	IGP / APA / EEA	1: 100 000	25 ha	Vetorial
CORINE Land Cover 2006	IGP / APA / EEA	1: 100 000	25 ha	Vetorial
Ortofotomapa 2005	DGRF/IGP	1: 10 000	0,5 m	Raster

3.3 Software utilizado

Foi utilizado o seguinte software na realização do trabalho:

- i. ArcGIS© – ArcCatalog© 9.3.1 com licença ArcEditor©;
- ii. ArcGIS ©– ArcMap© 9.3.1 com licença ArcEditor©;
- iii. ENVI© – versão 4.8;
- iv. Google Earth©- versão 5.2.1.

O software ArcCatalog© permitiu a criação das geodatabases necessárias para a digitalização, com os respetivos domínios (*domains*) das áreas de treino das diversas legendas testadas utilizadas.

O software ArcMap© permitiu a criação do projeto de digitalização dos sítios de treino, importando-se para o projeto as shapefiles de apoio à digitalização, assim como os mapas de ocupação do solo. No ambiente ArcMap© foi também adicionado um botão em Visual Basic, de forma a sincronizar a visualização da janela ArcMap© com o respetivo local no Google Earth©, ou vice-versa.

O ENVI© foi utilizado para tarefas de processamento das imagens ASTER, desde o pré-processamento (correção geométrica e atmosférica), passando pela classificação de imagens e posterior pós-classificação. O ENVI© possui uma integração direta com o ArcMap©, permitindo desta forma exportar os resultados do processamento de imagens diretamente para ArcMap©.

3.4 Pré-processamento das imagens ASTER

O pré-processamento das imagens ASTER (nível L1A) inclui a correção geométrica utilizando o modelo digital do terreno e a correção atmosférica, através do modelo FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) (Adler-Golden *et al.* 1999).

3.4.1 Correção geométrica

A correção geométrica efetuou-se através da ortoretificação dos subsistemas do VIF e IM das imagens, com o modelo digital do terreno gerado pelas bandas 3N e 3B das respetivas imagens. Este passo foi efetuado utilizando o método de reamostragem de imagem convolução cúbica (*cubic convolution*).

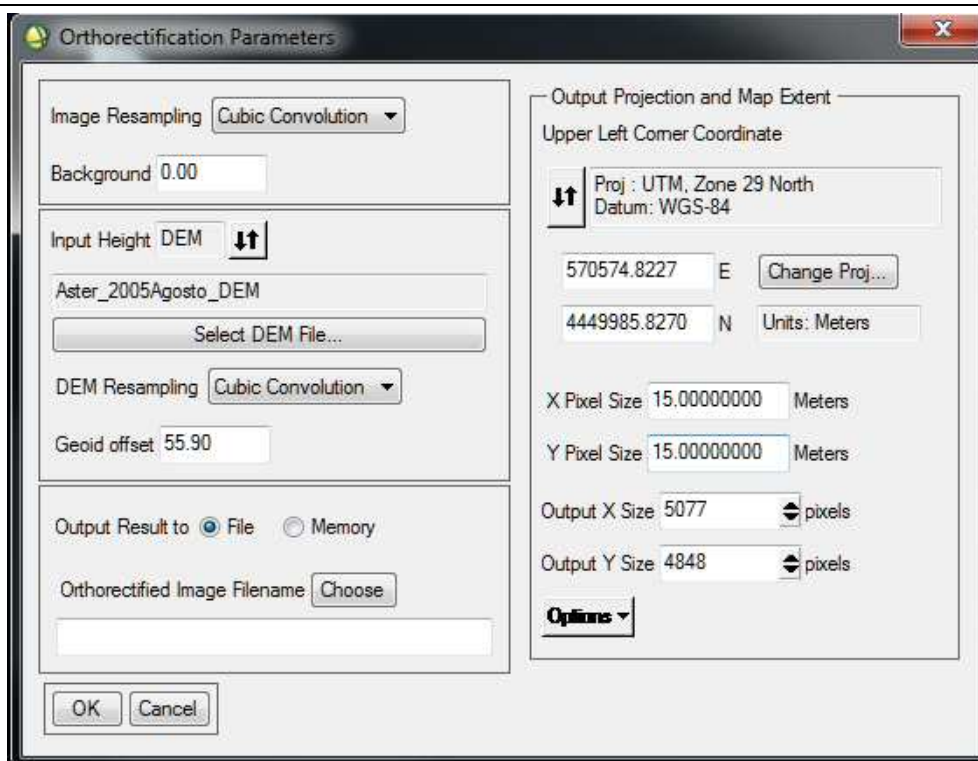


Figura 15 - Parâmetros da correção geométrica (imagem ASTER de agosto de 2005 - subsistema VIF).

De seguida procedeu-se à combinação dos subsistemas VIF e IM em apenas um ficheiro (*layer stacking*), e à uniformização da resolução dos subsistemas para 15 metros, pois o subsistema IM original tem um pixel de 30 metros, utilizando-se o método de reamostragem de imagem convolução cúbica. Posteriormente o *layer stacking* foi convertido para o formato BIL, de forma a poder ser processado no módulo FLAASH.

3.4.2 Correção atmosférica

A correção atmosférica pode ser feita a partir de várias metodologias distintas, como por exemplo: através de modelos de algoritmos radiométricos (MODTRAN - MODerate resolution TRANsmission model), ou tendo como base algoritmos empíricos. O primeiro é mais eficiente e sofisticado, exigindo o conhecimento das condições atmosféricas do local onde foi captada a imagem, os parâmetros detalhados de calibração radiométrica do sensor, dados técnicos do sensor, altitude, entre outros. Para a aplicação do método empírico é somente necessário a implementação de cálculos a partir dos dados (Níveis de Cinza), disponíveis nas próprias bandas (Agrawal e Sarup 2011).

A correção atmosférica foi efetuada com recurso ao módulo FLAASH. Este modelo permite a correção atmosférica de imagens multiespectrais e hiperespectrais capturadas no espectro visível, infravermelho próximo e médio, através do algoritmo MODTRAN (Adler-Golden *et al.* 1999). Os parâmetros latitude, longitude, dia e hora de recolha da imagem necessários para o preenchimento dos campos do módulo, foram retirados dos atributos globais (*global attributes*) de cada imagem ASTER. O campo elevação média foi calculado tendo por base a altimetria média da área de estudo. O modelo atmosférico MODTRAN utilizado para ambas as imagens foi o

de Média-Latitude Verão (*Mid-Latitude Summer*), sendo que o modelo de aerossol utilizado foi o rural (utilizado para zonas que não sejam muito afetadas por zonas urbanas muito densas).

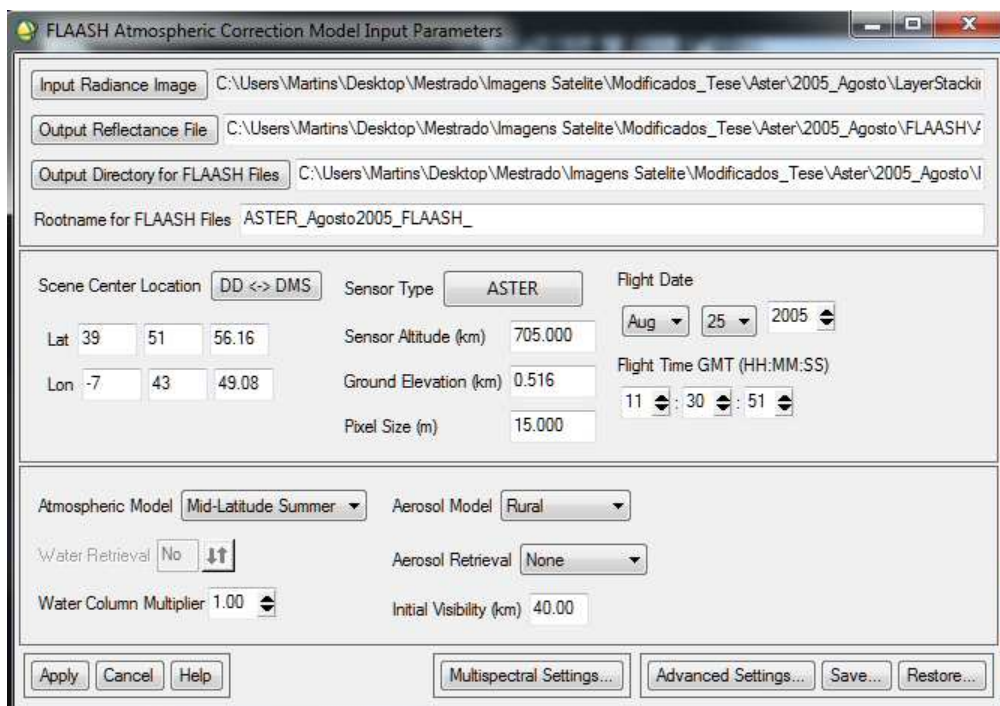


Figura 16 - Modelo FLAASH (imagem ASTER de agosto de 2005).

Finalmente extraíram-se as imagens pré-processadas através da intersecção entre as cenas ASTER e os limites do distrito de Castelo Branco.

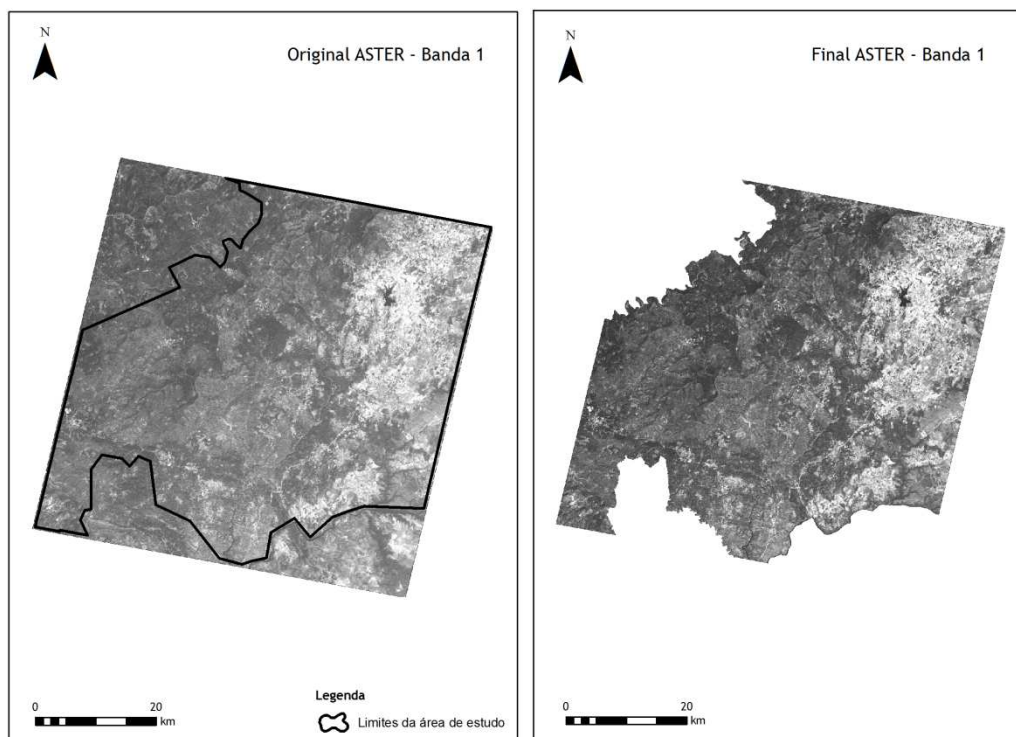


Figura 17 - Imagem ASTER original e final (Banda 1 de agosto de 2005).

3.5 Definição da legenda inicial

A nomenclatura de ocupação do solo adotada foi definida tendo por base a interpretação das classificações da Corine Land Cover 2000 e 2006 (IGP/APA/EEA) e da Carta de Ocupação do Solo 1990 e 2007 (IGP).

A nomenclatura original é composta por nove classes de vegetação e/ou ocupação do solo: áreas agrícolas (culturas permanentes e culturas temporárias) “Agriculturas”; Floresta de *Acacia dealbata* “Acácias”; Floresta de Azinheira e Sobreiro “Azinheira-Sobreiro”; Floresta de Castanheiro e Carvalho “Castanheiro-Carvalho”; Floresta de Eucalipto “Eucalipto”; Floresta de Resinosas “Resinosas”; Corpos de Água “Água”; Meios naturais e semi-naturais “Meios Naturais”; Territórios artificializados “Artificial”. Após a respetiva análise de separabilidade espectral (ver fase seguinte), a legenda original deu origem a outras três legendas adaptadas de forma a tentar incrementar a separabilidade entre todas as classes de vegetação e/ou ocupação do solo, com especial destaque para as manchas de *Acacia dealbata* e as classes espectralmente mais similares - legendas alteradas (Legenda Alt.1, Legenda Alt.2, Legenda Alt.3), assim como uma legenda final (Legenda alterada 4), de forma a inferir a separabilidade entre grandes classes genéricas de ocupação do solo em imagens ASTER (Tabela7).

Tabela 7 - Nomenclatura de ocupação do solo.

Legenda Original	Legenda Alt. 1	Legenda Alt. 2	Legenda Alt. 3	Legenda Alt. 4
Agrícolas	Agrícolas	Agrícolas	Agrícolas	Agrícolas
Acácias	Acácias	Acácias	Acácias	Florestas
Azinheira-Sobreiro	Folhosas	Florestas	Florestas	Água
Castanheiro-Carvalho	Resinosas	Água	Água	Artificial
Eucalipto	Água	Meios Naturais	Artificial	
Resinosas	Meios Naturais	Artificial		
Água	Artificial			
Meios Naturais				
Artificial				

Na legenda original foram digitalizados e validados 120 sítios de treino para cada classe de ocupação do solo, somando um total de 1 080 pontos. Posteriormente a *shapefile* com os pontos originais originou duas novas *shapefiles*: a primeira com 2/3 dos pontos para classificação (810 pontos) e os restantes 1/3 para validação de resultados (270 pontos).

Na legenda alterada 1 a classe “Folhosas” agregou os sítios de treino das classes da legenda anterior: “Azinheira-Sobreiro”, “Castanheiro-Carvalho” e “Eucalipto”.

A legenda alterada 2 apresentou uma nova classe, “Florestas”, na qual se juntaram os pontos de treino da legenda anterior: “Folhosas” e “Resinosas”.

Na legenda alterada 3, optou-se por se retirar a classe “Meios Naturais” de forma a estudar o seu efeito na separabilidade intra-classe.

Na legenda alterada 4 associaram-se os pontos das classes “Acácias” e “Florestas” numa nova classe “florestas”.

3.6 Separabilidade espectral

A análise da separabilidade espectral foi efetuada com a *shapefile* dos sítios de treino para classificação, utilizando-se para tal as 3 bandas do VIF e as 6 bandas do IM sendo aplicada a cada conjunto de classes da respetiva legenda adotada. Foi utilizada a medida de separabilidade da Divergência Transformada (DT).

3.7 Processamento

Para a extração das classes vegetação e ocupação do solo optou-se por uma abordagem ao nível do pixel recorrendo exclusivamente à classificação supervisionada. Deste modo, foram considerados três algoritmos distintos. Um classificador paramétrico convencional - classificador de máxima verossimilhança (MV) e dois métodos não paramétricos - classificador de máquinas de vetores de suporte (MVS) e redes neuronais artificiais (RNA). Cada classificador foi utilizado para classificar cada imagem ASTER - agosto de 2005 e março de 2007, com todas as legendas testadas, dando origem a 30 mapas de ocupação do solo.

Os algoritmos utilizados foram os seguintes:

- i. **Classificador de máxima verossimilhança (MV)**, com os seguintes parâmetros:
 - a. *Probability Threshold* = none
 - b. *Data Scale Factor* = 1




Figura 18 - Parâmetros do MV (agosto de 2005).

- ii. **Classificador de máquinas de vetores de suporte (MVS)**, com os seguintes parâmetros:
 - a. *Kernel Type* = *Radial Basis Function*
 - b. *Gamma in Kernel Function* = 0,111
 - c. *Penalty Parameter* = 100

- d. *Pyramid Levels* = 0
- e. *Classification Probability Threshold* = 0

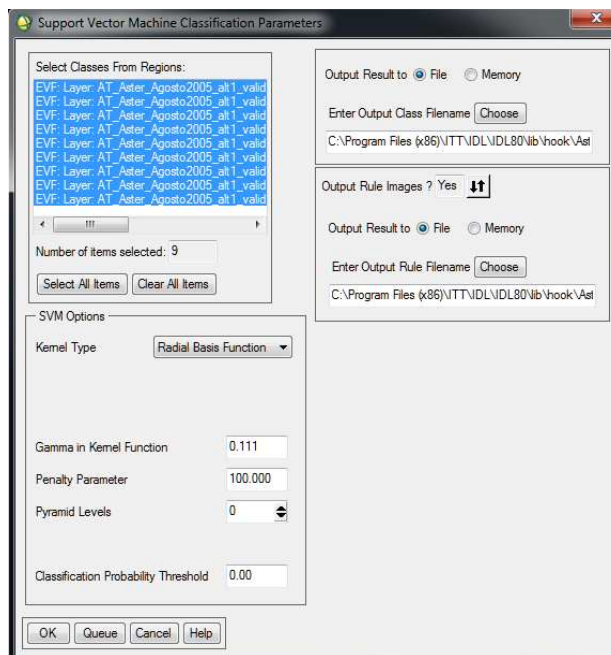


Figura 19 - Parâmetros do MVS (agosto 2005).

- iii. **Classificador das redes neuronais artificiais (RNA)**, com os seguintes parâmetros:
 - a. *Activation* = *Logistic*
 - b. *Training Threshold Contribution* = 0,9
 - c. *Training Rate* = 0,2
 - d. *Training Momentum* = 0,9
 - e. *Training RMS Exit Criteria* = 0,1
 - f. *Number of Hidden Layers* = 1
 - g. *Number of Training Iterations* = 1 000

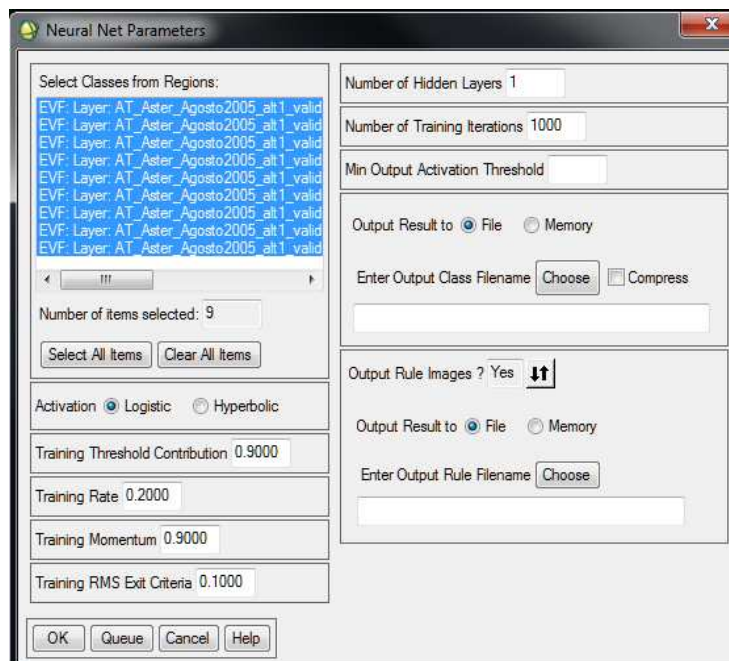


Figura 20 - Parâmetros das RNA (agosto 2005).

3.8 Pós-processamento

Para a avaliação dos resultados obtidos com os diversos classificadores, recorreu-se à obtenção das matrizes de confusão de cada uma das classificações obtidas, a partir das quais foram determinados índices de exatidão global (EG), exatidão do produtor das classes (EP), exatidão do utilizador das classes (EU) e índice Kappa geral (K) e por classe individual (KC).

4. Apresentação e discussão de resultados

As imagens ASTER produziram um conjunto de resultados que serão discutidos em grupo e individualmente. Desta forma os resultados serão apresentados por legenda adotada, as quais se representam individualmente por sub-capítulo (4.1 - Legenda original; 4.2 - Legenda alt.1; 4.3 - Legenda alt.2; 4.4 - Legenda alt.3; 4.5 - Legenda alt.4). Em cada sub-capítulo será analisada a separabilidade espectral da respetiva legenda, os resultados globais e individuais da classificação e a comparação dos resultados obtidos por cada classificador.

4.1 Legenda original - 9 classes

4.1.1 Separabilidade espectral

Na tabela 8 podem-se observar os valores obtidos pelas medidas de separabilidade adotadas para a legenda original no mês de agosto, retirando-se as seguintes conclusões:

- no geral, a separabilidade é moderada ou elevada entre classes, com os melhores resultados a serem registados com a classe (i);
- a classe “Acácias” tem uma generalizada falta de separabilidade, registando-se melhores resultados com as classes “Artificial” e “Água”. A reduzida separabilidade da “Acácias” é maior com a vegetação folhosa e resinosa densa, o que pode ser explicado por: uma reduzida área que muitas manchas de “Acácias” apresentam (tendo em conta que o pixel das imagens é de 15 metros), originando

uma refletância espectral distinta de manchas puras de acácia; muitas manchas de “Acácias” neste momento do ano têm um sub-coberto herbáceo muito semelhante.

Tabela 8 - Valores de separabilidade da legenda original - agosto de 2005.

Divergência Transformada

Classe	Agrícolas	Acácias	Azi_Sob	Cast_Car	Eucalipto	Resinosas	Água	M.Nat	Artificial
Agrícolas	0								
Acácias	1,78	0							
Azi_Sob	1,51	1,38	0						
Cast_Car	1,84	0,97	1,29	0					
Eucalipto	1,91	1,64	1,54	1,43	0				
Resinosas	1,99	1,46	1,87	1,48	1,33	0			
Água	1,79	1,83	1,75	1,82	1,93	1,97	0		
M.Nat	1,88	1,61	1,86	1,67	1,65	1,84	1,89	0	
Artificial	1,79	1,98	1,99	2,00	2,00	2,00	1,90	1,99	0

Legenda: Azi_Sob - “Azinheira-Sobreiro”; Cast_Car - “Castanheiro-Carvalho”; M.Nat. - “Meios Naturais”.

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

Na tabela 9 encontram-se os resultados obtidos pela medida de separabilidade aplicada à legenda original, para o mês de março de 2007, de onde se podem retirar as seguintes ilações:

- existe efetiva separabilidade entre a quase totalidade das classes, existindo apenas falta de separabilidade entre as classes “Agrícolas” e “Acácias”, “Acácias” e “Resinosas” e “Meios naturais” e “Artificial”;
- a má separabilidade que patenteia a classe “meios naturais” é consequência do carácter algo generalista e demasiado vago desta classe do ponto de vista espectral, que se reflete na maior abrangência dos seus valores de refletância, devendo afetar de modo negativo a classificação de pixéis que normalmente deveriam ser associados a outras classes mais específicas;
- a classe “Acácias” tem melhores resultados gerais em todas as classes (relativamente ao mês de agosto), o que se pode justificar pela altura do ano da imagem, pois geralmente em março, as mimosas estão em plena época de floração, que leva a valores de refletância espectral distinguíveis de outras classes;
- a classe “Acácias” tem elevada separabilidade com todas as classes menos com a classe “Agrícolas” e “Resinosas” em que a separabilidade é reduzida. A reduzida separabilidade com a classe “Agrícolas” pode ser explicada pela elevada diversidade dos valores de refletância da classe, e com a classe

“Resinosas” poderá ser devido à má classificação de sítios de treino das classes.

Tabela 9 - Valores de separabilidade da legenda original - março de 2007.

Divergência Transformada

Classe	Agrícolas	Acácias	Azi_Sob	Cast_Car	Eucalipto	Resinosas	Água	M.Nat	Artificial
Agrícolas	0								
Acácias	1,29	0							
Azi_Sob	2,00	2,00	0						
Cast_Car	1,90	1,93	2,00	0					
Eucalipto	2,00	2,00	2,00	2,00	0				
Resinosas	1,84	1,21	2,00	1,95	2,00	0			
Água	1,99	1,98	2,00	1,99	1,99	1,99	0		
M.Nat	1,99	1,97	2,00	1,98	1,99	1,99	1,92	0	
Artificial	2,00	2,00	2,00	2,00	1,99	2,00	1,97	1,52	0

Legenda: Azi_Sob - “Azinheira-Sobreiro”; Cast_Car - “Castanheiro-Carvalho”; M.Nat. - “Meios Naturais”.

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

4.1.2 Classificação

A tabelas 10 e 11 representam a matrizes de confusão obtidas usando a legenda original com os classificadores da máxima verosimilhança (MV), redes neuronais artificiais (RNA) e máquinas de vetores de suporte (MVS) nos meses de agosto de 2005 e março de 2007.

4.1.2.1 Máxima Verosimilhança

Relativamente aos resultados obtidos pelo classificador da máxima verosimilhança (MV), estes foram bastante satisfatórios, registando uma exatidão global (EG) de 85% e Kappa de 0,83 (Excelente) no mês de março e EG de 73% e Kappa de 0,7 (Muito bom) no mês de agosto (Tabelas 10 e 11).

No que diz respeito à exatidão do produtor (EP), ou seja os erros de omissão, pode-se verificar que esta tem valores superiores no mês de março, sendo a classe “Acácias” a apresentar um valor mais baixo, de cerca de 70%. No mês de agosto a EP tem valores inferiores, indo do 35% da classe “Azinheira-Sobreiro” até aos 94,44% da classe “Água”.

Em relação à exatidão do utilizador (EU), ou erros de comissão, os valores foram novamente mais elevados no mês de março, realçando-se a classe “Acácias” com 100% e a classe “Artificial” (0,93%) como aquelas que registaram valores mais elevados. Comparando a EU da classe “Acácias” no mês de março (100%) e no mês de agosto (60%), confirma-se a análise da

separabilidade, em que se constatou uma melhor separabilidade da classe no mês de março (mês de floração).

Os baixos valores de EP e EU de algumas classes no mês de agosto indiciam confusão entre classes. Parte dos erros é entre classes espectralmente próximas, como por exemplo entre “Acácias” e “Azinheira-Sobreiro”, entre “Acácias” e “Castanheiro-Carvalho” ou entre “Castanheiro-Carvalho” e “Azinheira-Sobreiro”. A confusão entre as classes pode ser explicada pela relativa semelhança espectral entre as espécies no pico do verão.

Os valores de Kappa (K) são globalmente superiores no mês de março, sendo o valor mais baixo apresentado pela classe “Eucalipto” com 0,64. Os valores mais elevados estão em sintonia com os registados pela EU, apresentados pelas classes “Acácias” (K=1) e a classe “Artificial” (K=0,93).

Analisando os resultados do principal objetivo do trabalho de projeto, a cartografia da *Acacia dealbata*, destacam-se os seguintes resultados:

- na generalidade a *Acacia dealbata* teve melhores resultados no mês de março (K=1), denotando-se a influência que a época de floração tem num mapeamento mais eficaz da espécie;
- os piores resultados da EU no mês de agosto reforçam a ideia da reduzida separabilidade que a espécie tem no Verão, havendo uma confusão espectral especialmente com outras espécies folhosas, como a “Azinheira-Sobreiro” e “Castanheiro-Carvalho”, que poderá significar a classificação errada de áreas com estas tipologias como “Acácias”.

4.1.2.2 Redes Neurais Artificiais

Analisando os resultados obtidos pelo classificador das redes neuronais artificiais (RNA), destaca-se a menor precisão dos resultados relativamente ao classificador anteriormente analisado (MV), registando uma exatidão global (EG) de 47,93% e Kappa (K) de 0,42 (Bom) em agosto de 2005 e EG de 55,93% e K de 0,5 (Bom) em março de 2007 (Tabelas 10 e 11).

A exatidão do produtor (EP) confirmou os piores resultados obtidos no MV, realçando-se os baixos valores das classes “Acácias”, “Azinheira-Sobreiro”, “Castanheiro-Carvalho” e “Eucalipto” no mês de agosto, reforçando a reduzida separabilidade entre espécies folhosas no verão. Pela positiva encontram-se as classes “Água” (83,33%), “Artificial” (77,78%) e “Agrícolas” (77,27%) em março e “Resinosas”, “Água” e “Artificial” (todas com 72,22%) em agosto.

Relativamente à exatidão do utilizador (EU), verificou-se uma tendência em ambos os meses, com as classes “Agrícolas” (90,91% em agosto e 77,27% em março), “Acácias” (66,67% em agosto e 59,09% em março) e “Água” (68,42% em agosto e 75% em março), a apresentarem os melhores resultados entre as classes utilizadas na legenda.

O índice Kappa (K) obteve resultados assinaláveis nas classes “Agrícolas” (agosto = 0,9 e março = 0,74), “Castanheiro-Carvalho” em março (K=1) e “Água” em março (K=1).

A classe “Acácias” registou valores moderadamente satisfatórios, não se destacando a capacidade de diferenciação na classificação evidenciada pelo classificador da MV, sendo os valores K de agosto superiores aos do mês de março (K= 0,61 e K= 0,53 respetivamente).

4.1.2.3 Máquinas de Vetores de Suporte

Os resultados da aplicação do classificador das máquinas de vetores de suporte (MVS) foram os mais baixos no conjunto dos classificadores utilizados, registando uma exatidão global (EG) de 40,24% e Kappa (K) de 0,32 (Razoável) no mês de agosto de 2005 e uma EG de 43,5% e K de 0,36 (Razoável) no mês de março de 2007. É de salientar que a classe “Resinosas” não foi classificada pelo classificador, muito provavelmente devido ao facto da reduzida separabilidade da espécie com outras classes, que fez com que o classificador não conseguisse associar pixéis a esta classe (Tabelas 10 e 11).

Os valores da exatidão do produtor (EP) e exatidão do utilizador (EU) são bastante reduzidos, sendo apenas de realçar a EU da classe “Meios Naturais” no mês de março (100%).

Apesar de na generalidade das classes, os Kappa (K) serem bastante baixos, são de destacar os registados pelas classes “Agrícolas” em agosto (K= 0,72) e “Artificial” (K=0,66) e “Eucalipto” (K=0,63) em março.

Relativamente aos resultados da classe “Acácias”, esses são bastante reduzidos, sendo mesmo os mais baixos entre os classificadores utilizados.

Tabela 10 - Matriz de confusão da legenda original - agosto de 2005.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícolas	81,82	85,71	0,84	55,56	90,91	0,90	50	75	0,72
Acácias	78,26	60	0,54	8,7	66,67	0,61	69,57	32,65	0,22
Azinhreira-Sobreiro	35	100	1	39,13	47,37	0,39	56,52	30,95	0,20
Castanheiro-Carvalho	77,27	51,52	0,45	40	50	0,45	26,67	50	0,45
Eucalipto	88,89	80	0,78	16,67	30	0,22	11,11	20	0,10
Resinosas	66,67	66,67	0,63	72,22	27,08	0,18	0	0	0
Água	94,44	100	1	72,22	68,42	0,65	44,44	53,33	0,48
Meios Naturais	61,11	64,71	0,61	66,67	75	0,72	44,44	57,14	0,52
Artificial	77,78	100	1	72,22	41,94	0,35	44,44	42,11	0,35
EG	73,44			47,93			40,24		
Kappa	0,7			0,42			0,32		

Tabela 11 - Matriz de confusão da legenda original - março de 2007.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícolas	88,89	84,21	0,82	77,27	77,27	0,74	81,82	58,06	0,52
Acácias	69,57	100	1	56,52	59,09	0,53	56,52	26	0,15
Azinhreira-Sobreiro	86,96	90,91	0,89	45	60	0,55	55	32,35	0,24
Castanheiro-Carvalho	86,67	92,86	0,92	13,64	100	1	4,55	33,33	0,24
Eucalipto	83,33	68,18	0,64	44,44	47,06	0,41	22,22	66,67	0,63
Resinosas	94,44	80,95	0,79	66,67	46,15	0,40	0	0	0
Água	83,33	88,24	0,87	83,33	75	0,72	72,22	44,83	0,39
Meios Naturais	94,44	77,27	0,75	44,44	25	0,17	5,56	100	1
Artificial	83,33	93,75	0,93	77,78	70	0,67	88,89	69,57	0,66
EG		85,21			55,93			43,5	
Kappa		0,83			0,5			0,36	

4.1.2.4 Comparação de resultados

A utilização da mesma informação ao nível dos sítios de treino para os três classificadores utilizados, permite a comparação de resultados entre estes. Assim, de seguida serão comparados os resultados da exatidão global (EG) e Kappa dos classificadores utilizados nas imagens de agosto e março.

Da leitura da tabela 12, constata-se que os melhores resultados foram registados no classificador MV, com maior destaque para o mês de março (EG = 85,21% e K= 0,83). Os resultados obtidos pelos classificadores RNA e MVS foram claramente inferiores aos registados pela MV.

Tabela 12 - Valores de exatidão global e Kappa- legenda original.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
EG	73,44	47,93	40,24	85,21	55,93	43,5
Kappa	0,7	0,42	0,32	0,83	0,5	0,36

A figura 21 representa o mapa de ocupação do solo resultante do classificador com os melhores resultados globais (MV de Março).

No mês de agosto a classe “Acácias” registou a maior área de ocupação do solo de todas as classes utilizadas (760 km²), seguido da classe “Resinosas” (726 km²). A elevada área classificada como “Acácias” põe em evidência a confusão espectral da espécie com outras folhosas no verão, tendo o classificador delimitado áreas de *Acacia dealbata* que provavelmente pertencerão a outras classes (Tabela 13).

Relativamente ao mês de março, as classes com maior área de ocupação pertencem às “Resinosas” (785 km²), “Eucalipto” (635 km²) e “Agrícolas” (349,6 km²) (Tabela 13).

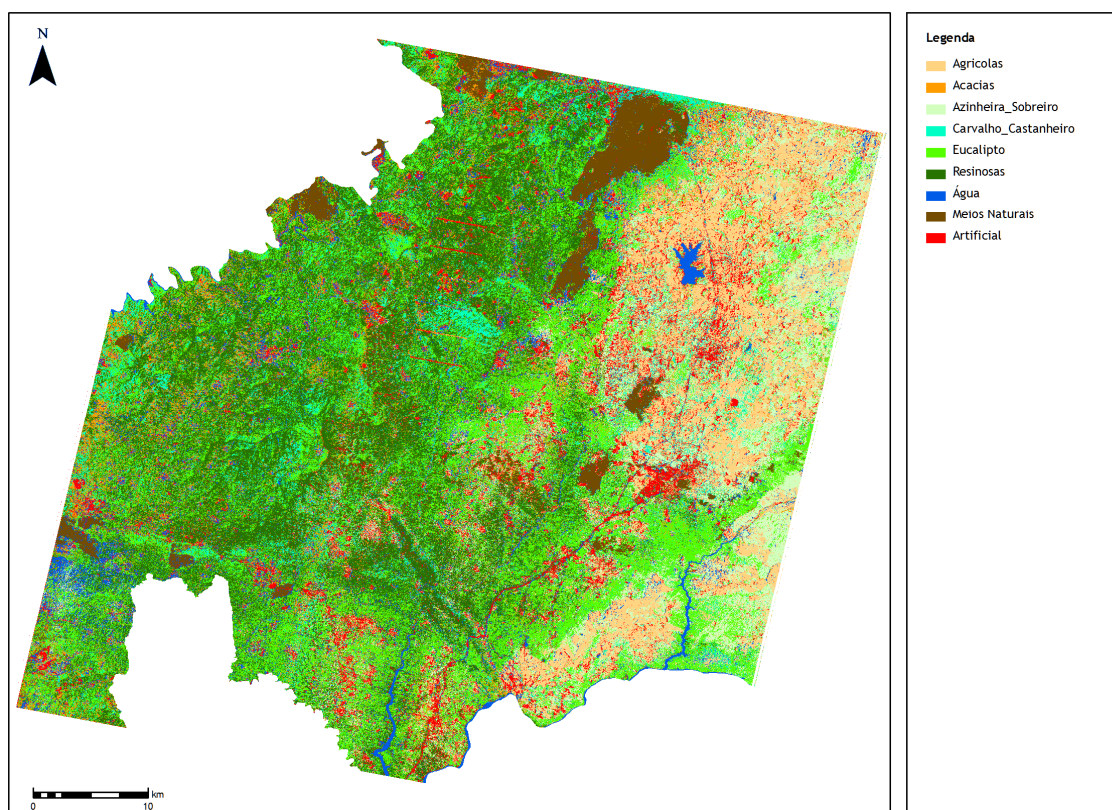


Figura 21 - Mapa de ocupação do solo da legenda original, classificador da MV - - março 2007.


Tabela 13 - Área (km²) das classes da legenda original, classificador da MV.

Classe	Agosto de 2005	Março de 2007
Agrícolas	661,2	349,6
Acácias	760,5	247,7
Azinheira-Sobreiro	78,2	309,8
Castanheiro-Carvalho	280,8	206,6
Eucalipto	161,0	635,3
Resinosas	726,2	785,7
Água	116,8	293,9
Meios Naturais	257,0	154,5
Artificial	169,5	228,3

Os valores dos índices de exatidão do produtor (EP), exatidão do utilizador (EU) e Kappa (K) obtidos para cada classificador e por classe apresentam-se nas figuras 22, 23 e 24, respectivamente.

Relativamente à exatidão do produtor verifica-se uma clara superioridade nos resultados obtidos pelo classificador MV na quase totalidade das classes utilizadas, mais concretamente nas classes: “Agrícolas”; “Acácias”; “Azinheira-Sobreiro”; “Eucalipto”; “Resinosas”; “Água”;


“Artificial”. Por sua vez, a classe “Catanheiro-Carvalho” foi melhor classificada pelas RNA, enquanto a classe “Meios Naturais” foi pelas MVS.



Legenda: Azi_Sob - “Azinheira-Sobreiro”; Cast_Car - “Castanheiro-Carvalho”; M.Nat. - “Meios Naturais”.

Figura 22 - Avaliação do índice de exatidão do produtor dos classificadores, legenda original - agosto de 2005 e março de 2007.

Analisando a figura 23, relativa à exatidão do utilizador (EU), denota-se mais uma vez um predomínio de melhores resultados obtidos pelo classificador MV, estando nessa situação as classes: “Acácias”; “Azinheira-Sobreiro”; “Eucalipto”; “Resinosas”; “Água”; “Artificial”. A classe “Agrícolas” teve melhor resultado pelo classificador das RNA, sendo que na classe “Meios Naturais” foi obtido pelo classificador MVS.



Legenda: Azi_Sob - “Azinheira-Sobreiro”; Cast_Car - “Castanheiro-Carvalho”; M.Nat. - “Meios Naturais”.

Figura 23 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda original - agosto de 2005 e março de 2007.

Da análise dos resultados obtidos pelos Kappa de cada classe, são reforçados os resultados registados pela análise da exatidão do utilizador, não existindo nenhuma classe que tenha resultados diferentes dos obtidos anteriormente.




Figura 24 - Determinação do índice Kappa dos classificadores, legenda original - agosto de 2005 e março de 2007.

4.2 Legenda alterada 1 - 7 classes

4.2.1 Separabilidade espectral

Os valores obtidos pela medida de separabilidade na legenda alterada 1 (Tabelas 14 e 15) no mês de agosto e de março são bastante similares aos registados com a legenda original.

No caso da classe “Acácias” manteve-se a fraca separabilidade espectral com a classe “Folhosas1” (junção de “Azinheira-Sobreiro”, “Eucalipto” e “Castanheiro-Carvalho”) e com a classe “Resinosas1” em agosto e com as classes “Agrícolas1” e “resinosas1” em março. Denota-se um evidente incremento de separabilidade da “Acácias” com outras folhosas do mês de agosto para março, havendo por outro lado, um decréscimo de separabilidade da classe “Agrícolas” entre março e agosto, o que pode ser justificado pela provável uniformidade de culturas no verão (agosto), em que normalmente os campos se encontram lavrados/sem culturas e da heterogeneidade de culturas em março. Por sua vez, a classe “Resinosas” mantém fracos resultados de separabilidade em ambos os meses, de acordo com o observado para a legenda inicial.

Tabela 14 - Valores de separabilidade da legenda alterada 1 - agosto de 2005.

Divergência Transformada

Classe	Agrícolas1	Acácias1	Folhosas1	Resinosas1	Água1	Meios Naturais1	Artificial1
Agrícolas1	0						
Acácias1	1,78	0					
Folhosas1	1,80	0,97	0				
Resinosas1	1,96	1,31	1,57	0			
Água1	1,93	1,83	1,92	1,94	0		
Meios Naturais1	1,89	1,83	1,93	1,57	1,86	0	
Artificial1	1,66	1,97	2,00	2,00	1,91	1,98	0

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade

<1,7 Falta separabilidade

Tabela 15 - Valores de separabilidade da legenda alterada 1 - março de 2007.

Divergência Transformada

Classe	Agrícolas1	Acácias1	Folhosas1	Resinosas1	Água1	Meios Naturais1	Artificial1
Agrícolas1	0						
Acácias1	1,29	0					
Folhosas1	1,94	1,98	0				
Resinosas1	1,84	1,21	1,99	0			
Água1	1,99	1,98	1,99	1,99	0		
Meios Naturais1	1,99	1,97	1,99	1,99	1,92	0	
Artificial	2,00	2,00	2,00	2,00	1,97	1,52	0

>1,9 Efetiva separabilidade
 1,7 - 1,9 Moderada separabilidade
 <1,7 Falta separabilidade

4.2.2 Classificação

De seguida apresentam-se os principais resultados obtidos pelos classificadores da máxima verosimilhança (MV), redes neuronais artificiais (RNA) e máquinas de vetores de suporte (MVS) para as imagens ASTER de agosto de 2005 e março de 2007, respetivamente, aplicados à legenda alterada 1.

4.2.2.1 Máxima Verosimilhança

Relativamente aos resultados obtidos pelo classificador da máxima verosimilhança (MV), estes foram ligeiramente superiores no mês de março relativamente à legenda anterior, registando uma exatidão global (EG) de 85% e Kappa de 0,87 (Excelente), sendo que no mês de agosto foi um pouco mais baixo, com uma EG de 72% e Kappa de 0,68 (Muito bom) (Tabelas 16 e 17).

Os resultados da exatidão do produtor (EP), são globalmente superiores no mês de março, com a classe “Acácias1” a apresentar o valor mais baixo, cerca de 76%, vindo confirmar a boa separabilidade registada anteriormente. No mês de agosto, confirma-se a reduzida separabilidade da classe “Folhosas1”, pois a classe teve uma EP de apenas 24%.

Em relação à exatidão do utilizador (EU), os valores mais elevados ocorrem novamente no mês de março, com as classes “Agrícolas1” e “Artificial1” a apresentarem uma EU de 100%. Em agosto podem-se realçar os resultados da classe “Água1” e “Artificial1” (100% e 93,75% respetivamente). Na análise da classe “Acácias1” confirmam-se os resultados da separabilidade espectral da legenda alterada1 (é superior no mês de março), sendo o EU em março de 84,21% e em agosto de 60,61%.

Analisando em conjunto os valores da EP e EU, constata-se que a similaridade espectral que existia principalmente entre espécies folhosas no mês de agosto da legenda original, fazendo decrescer os resultados, praticamente desapareceu com a agregação das diferentes coberturas florestais em classes mais abrangentes, aumentando com isso substancialmente os resultados.

Comparando os valores de Kappa (K) de agosto e março, estes são superiores em quase todas as classes da legenda do mês de março, não o sendo para as classes “Folhosas1” e “Água1” que tiveram melhores valores em agosto. Os valores mais elevados são apresentados pelas classes “Água1” em agosto, “Agrícolas1” e “Artificial1” em março, com Kappas de 1.

Analisando os resultados do principal objetivo do trabalho de projeto, a cartografia da *Acacia dealbata*, destacam-se os seguintes resultados:

- o K da espécie é superior no mês de março, ficando novamente comprovada a influência da floração para um mapeamento mais fiável;
- os resultados pouco positivos da EU em agosto vêm de encontro à fraca separabilidade evidenciada na divergência transformada com a classe “Folhosas1”.

4.2.2.2 Redes Neurais Artificiais

Relativamente aos resultados gerais obtidos pelo classificador das redes neuronais artificiais (RNA), estes foram inferiores aos registados pelo classificador MV com a mesma legenda. Os valores de Kappa (K) e exatidão global (EG) são praticamente semelhantes aos registados pelo classificador na legenda anterior, sendo o EG de 49,24% e Kappa de 0,41 em agosto (Bom) e EG de 55,63% e Kappa de 0,48 (Bom) em março. A classe “Acácias1” não foi classificada no mês de agosto, o que pode ser justificado pela falta de separabilidade da classe (confirmada pela análise da divergência transformada em agosto), levando o classificador a não associar pixels a esta classe (Tabelas 16 e 17).

Os resultados da exatidão do produtor (EP) tiveram resultados diferentes em cada mês. No mês de agosto as classes com piores resultados foram: “Agrícolas1” (38,89%); “Acácias1” (0%); “Artificial1” (16,67%). No mês de março os piores resultados foram os das classes: “Folhosas1” (8%); “Resinosas1” (44,44%); “Meios Naturais1” (38,89%). As restantes classes, em ambos os meses tiveram resultados globalmente positivos, destacando-se “Resinosas1” em agosto (88,89%) e “Agrícolas1” em março.

Analisando a exatidão do utilizador (EU), os resultados foram bastante reduzidos nas classes “Resinosas1” (29,09%) em agosto, “Folhosas1” em agosto e março (41,94% e 28,57% respetivamente) e “Meios Naturais1” em março (31,82%). Pela positiva destacam-se as classes “Artificial1” em agosto e março (100% e 81,25% respetivamente), “Água1” em ambos os meses (86,67% em agosto e 87,5% em março) e “Agrícolas1” em agosto (87,5%).

O índice Kappa (K) confirmou os bons resultados das classes melhores classificadas na EU, com as classes “Água1” (K= 0,85 em agosto e K= 0,86 em março) “Artificial1” (K= 1 em agosto e K= 0,79 em março) e “Agrícolas1” (K= 0,86 em agosto) a obterem os melhores resultados.

A classe “Acácias” foi apenas classificada no mês de março, sendo o resultado bastante reduzido (K= 0,39). Pela aplicação do classificador não é perceptível a separabilidade evidenciada anteriormente entre os meses de agosto e março.

4.2.2.3 Máquinas de Vetores de Suporte

Tal como na legenda anterior (Legenda original) a aplicação do classificador das máquinas de vetores de suporte (MVS) registou os piores resultados globais, entre os classificadores usados, com uma exatidão global (EG) de 44,7% e Kappa de 0,35 (Razoável) em agosto e EG de 47,18% e Kappa de 0,38 (Razoável) em março. A classe “Resinosas1” não foi classificada, muito provavelmente devido ao facto da reduzida separabilidade da espécie com outras classes, que fez com que o classificador não tivesse associado quaisquer pixéis a esta classe (Tabelas 16 e 17).

A exatidão do produtor (EP) tem valores assinaláveis nas classes “Agricultoras1” em agosto e março (83,33% e 81,82% respetivamente), “Meios Naturais1” em agosto (77,78%), “Folhosas1” (76%) em março e “Água1” e “Artificial1” em março (ambos com 72,22%).

Relativamente à exatidão do utilizador (EU) podem-se destacar os resultados positivos da classe “Água1” em agosto (75%), “Meios Naturais1” (100%) e “Artificial1” (81,25%) em março. A classe “Acácias1” teve resultados relativamente positivos no mês de março (66,67%), sendo quase o dobro do valor registado em agosto (32,35%).

Na generalidade das classes, os Kappa (K) são bastante baixos, sendo que os melhores resultados estão em consonância com os registados com a EU. Relativamente aos resultados da classe “Acácias”, é de destacar o Kappa do mês de março (0,60), denotando-se a diferença já comentada do aumento de precisão na cartografia da espécie entre os meses de agosto e março.

Tabela 16 - Matriz de confusão da legenda alterada 1 - agosto de 2005.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agricultoras1	81,82	78,26	0,74	38,89	87,5	0,86	83,33	62,5	0,57
Acácias1	86,96	60,61	0,53	0	0	0	52,38	32,35	0,20
Folhosas1	24	85,71	0,83	61,9	41,94	0,31	33,33	29,17	0,16
Resinosas1	83,33	57,69	0,52	88,89	29,09	0,18	0	0	-0,16
Água1	94,44	100	1	72,22	86,67	0,85	16,67	75	0,71
Meios Naturais1	66,67	60	0,54	72,22	65	0,59	77,78	46,67	0,38
Artificial1	83,33	93,75	0,93	16,67	100	1	50	60	0,54
EG	72,53			49,24			44,7		
Kappa	0,68			0,41			0,35		

Tabela 17 - Matriz de confusão da legenda alterada 1 - março de 2007.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícolas1	88,89	100	1	81,82	64,29	0,58	81,82	62,07	0,55
Acácias1	76,19	84,21	0,81	73,91	48,57	0,39	8,7	66,67	0,60
Folhosas1	85,71	81,82	0,78	8	28,57	0,13	76	30,16	0,15
Resinosas1	83,33	78,95	0,76	44,44	44,44	0,36	5,56	50	0,43
Água1	100	90	0,88	77,78	87,5	0,86	72,22	46,43	0,39
Meios Naturais1	94,44	80,95	0,78	38,89	31,82	0,22	5,56	100	1
Artificial1	83,33	100	1	72,22	81,25	0,79	72,22	81,25	0,79
EG		87,12			55,63			47,18	
Kappa		0,85			0,48			0,38	

4.2.2.4 Comparação de resultados

A tabela 18 representa os resultados globais de exatidão global (EG) e Kappa dos classificadores utilizados, de forma a permitir a comparação de resultados entre estes.

O classificador com melhores resultados em ambos os meses foi o da máxima verosimilhança (MV), destacando-se nitidamente o mês de março, com uma EG de 87,12% e Kappa de 0,85 (superior à legenda anterior que era de 0,83). Os classificadores das redes neuronais artificiais (RNA) e máquinas de vetores de suporte (MVS) tiveram resultados globais substancialmente inferiores, sendo as MVS aquelas que obtiveram resultados mais fracos em ambos os meses (K= 0,35 em agosto e K= 0,38 em março). É de salientar que todos os classificadores tiveram melhores resultados em março, o que reforça a convicção do melhor mapeamento geral nessa altura do ano.

Tabela 18 - Valores de exatidão global e Kappa- legenda alterada 1.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
EG	72,53	49,24	44,7	87,12	55,63	47,18
Kappa	0,68	0,41	0,35	0,85	0,48	0,38

A figura 25 representa a ocupação do solo definida pela legenda alterada 1 obtida pelo classificador com melhores resultados globais no mês de agosto de 2005 e março de 2007, que neste caso foi o da MV de março.

Em relação ao mês de agosto, a classes “Acácias1” regista a maior área de ocupação (887 km²), seguida pela “Resinosas1” (796 km²) e “Agrícolas1” (713 km²). Tal como na legenda anterior (legenda original) fica perceptível a possível confusão espectral entre a classe “Acácias1” e “Folhosas1”, que leva a que possíveis áreas de folhosas sejam classificadas como *Acacia dealbata* (Tabela 19).

No mês de março, as classes com maior área de ocupação são as de “Resinosas1” (1 098 km²), “Folhosas1” (630 km²), “Acácias1” (436 km²) e “Agrícolas1” (432 km²) (Tabela 19).

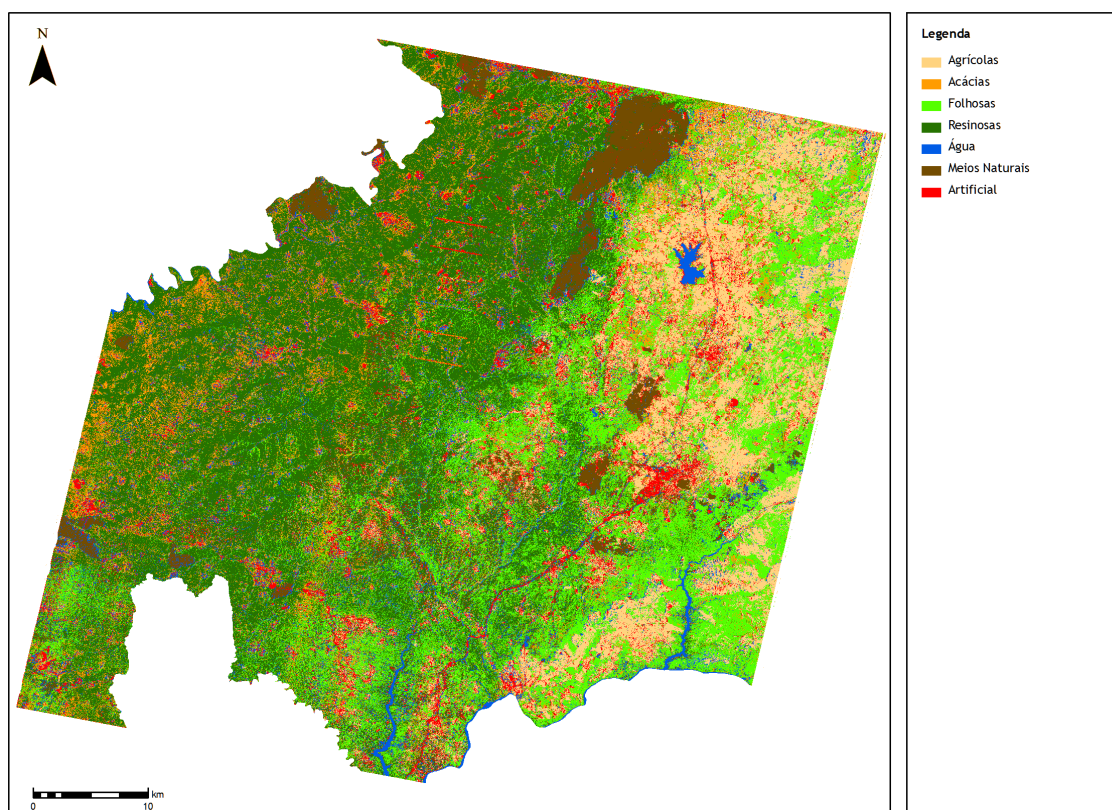


Figura 25 - Mapa de ocupação do solo da legenda alt1, classificador da MV - março 2005

Tabela 19 - Área (km²) das classes da legenda alt1, classificador da MV.

Classe	Agosto	Março
Agrícolas1	713,7	432,0
Acácias1	887,4	436,9
Folhosas1	196,2	630,9
Resinosas1	796,1	1098,0
Água1	131,2	203,8
Meios Naturais1	275,5	187,9
Artificial1	211,1	221,8

As figuras 26, 27 e 28 dizem, respectivamente, respeito à exatidão do produtor (EP), exatidão do utilizador (EU) e Kappa condicional (KC) de cada classe da legenda.

Analisando a EP, destaca-se o classificador MV como aquele que tem melhores resultados na quase totalidade das classes (“Agrícolas1”; “Acácias1”; “Folhosas1”; “Água1”; “Meios Naturais1”; “Artificiais1”), não o sendo apenas na classe “Resinosas1”, a qual tem melhores resultados pelo classificador das RNA.




Figura 26 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.

Relativamente à figura 27, que diz respeito à exatidão do utilizador, existe uma elevada percentagem de classes que são melhores classificadas com o classificador MV (“Agrícolas1”; “Acácias1”; “Folhosas1”; “Resinosas1”; “Água1”; “Artificial1”) (*ex equo* com RNA). A classe “Meios Naturais1” obteve melhor classificação nas MVS, enquanto que a classe “Artificial1” foi com o classificador RNA (*ex equo* com o MV).




Figura 27 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.

Os resultados do índice Kappa para cada classe da legenda são em tudo semelhantes à EU anteriormente analisada, destacando-se os $K = 1$ nas classes: “Agrícolas1” (MV em março); “Água1” (MV em agosto); “Meios Naturais1” (MVS em março); “Artificial1” (RNA em agosto e MV em março).




Figura 28 - Determinação do índice Kappa dos classificadores, legenda alt1 - agosto de 2005 e março de 2007.

4.3 Legenda alterada 2 - 6 classes

4.3.1 Separabilidade espectral

Na análise da separabilidade da legenda alterada 2 no mês de agosto (Tabela 20), constatou-se que a junção da classe “Folhosas1” e “Resinosas1” numa nova classe “Florestas2” não produziu resultados na melhoria da separabilidade com a “Acácias2”. A classe “Acácias2” manteve os restantes resultados praticamente semelhantes à legenda anterior, no entanto, a separabilidade com a classe “Meios Naturais2” que era moderada na legenda anterior (Legenda alterada 1), passou para falta de separabilidade.

Tabela 20 - Valores de separabilidade da legenda alterada 2 - agosto de 2005.

Divergência Transformada

Classe	Agrícolas2	Acácias2	Florestas2	Água2	Meios Naturais2	Artificial2
Agrícolas2	0					
Acácias2	1,84	0				
Florestas2	1,83	1,24	0			
Água2	1,93	1,92	1,96	0		
Meios Naturais2	1,90	1,65	1,79	1,90	0	
Artificial	1,65	1,97	2,00	1,90	1,98	0

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

No mês de março (Tabela 21) manteve-se a falta de separabilidade da classe “Acácias2” com “Agrícolas2”, havendo no entanto um incremento de separabilidade entre a classe “Acácias2” com a nova classe “Florestas2” (surgiu da conjugação das classes “Folhosas1”, que tinha uma efetiva separabilidade e da classe “Resinosas1” que tinha falta de separabilidade), o que potencialmente poderá incrementar os resultados na classificação. As restantes classes não obtiveram alterações significativas.

Tabela 21 - Valores de separabilidade da legenda alterada 2 - março de 2007.

Divergência Transformada

Classe	Agrícolas2	Acácias2	Florestas2	Água2	Meios Naturais2	Artificial2
Agrícolas2	0					
Acácias2	1,29	0				
Florestas2	1,78	1,74	0			
Água2	1,99	1,98	1,98	0		
Meios Naturais2	1,99	1,97	1,98	1,92	0	
Artificial2	2,00	2,00	1,99	1,97	1,52	0

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

4.3.2 Classificação

As tabelas 22 e 23 representam os resultados globais e por categoria da legenda alterada 2 na classificação efetuada pelos classificadores da máxima verosimilhança, redes neuronais artificiais e máquinas de vetores de suporte, nos meses de agosto de 2005 e março de 2007, respetivamente.

4.3.2.1 Máxima Verosimilhança

Os resultados gerais do classificador MV no mês de março foram praticamente semelhantes à legenda anterior (Legenda alterada 1) no mesmo período, com uma exatidão global (EG) de 87,72% e Kappa (K) de 0,85 (Excelente). No mês de agosto, os resultados globais são inferiores aos do mês de março, com uma EG de 77,42% e Kappa de 0,73 (Muito bom), no entanto estes resultados são ligeiramente superiores aos da legenda anterior no mesmo período de tempo.

Relativamente à exatidão do produtor (EP), os resultados são globalmente superiores no mês de março, sendo o valor mais baixo apresentado pela classe “Florestas2” (76,19%) e o máximo pela classe “Acácias2” (95,24%). No mês de agosto os resultados são maioritariamente satisfatórios, com apenas a classe “Florestas2” a apresentar uma classificação “negativa” (40%) (essencialmente devido à confusão espectral com a classe “Acácias2”).

Examinando os valores das categorias na exatidão do utilizador (EU), percentualmente, os resultados são superiores no mês de março, com a classe “Artificial2” a apresentar uma EU de 100%. Apesar de os valores de EU serem inferiores no mês de agosto, é de assinalar a existência de duas classes com EU de 100%, sendo estas “Florestas2” e “Água2”.

Examinando em conjunto os resultados da EP e da EU, é perceptível a confusão espectral existente entre as classes “Acácias2” e “Florestas2” no mês de agosto, levando a que muitos locais de *Acacia dealbata* sejam posteriormente classificados como florestas. No mês de março, com o aumento de separabilidade entre as classes, melhora substancialmente os resultados de classificação das espécies.

Comparando os valores de Kappa entre os meses de agosto e março, esses são superiores na quase totalidade das classes utilizadas (“Agrícolas2”; “Acácias2”; “Meios Naturais2”; “Artificial2”) no mês de março. Em agosto as restantes classes “Florestas2” e “Água2” obtêm melhores resultados ($K=1$).

O índice Kappa para a classe “Acácias2” é superior em março ($K=0,72$), realçando a boa separabilidade entre espécies na época de floração da *Acacia dealbata*.

4.3.2.2 Redes Neurais Artificiais

O classificador das redes neuronais artificiais (RNA) obteve resultados gerais inferiores aos apresentados pelo classificador da máxima verosimilhança em ambos os meses analisados. No entanto, é de destacar a ligeira melhoria de resultados em ambos os meses, relativamente aos mesmos períodos da legenda anterior (Legenda alterada1), resultando numa exatidão global (EG) de 55,26% e Kappa (K) de 0,46 (Bom) em agosto e EG de 66,13% e Kappa de 0,59 (Bom) em março. A classe “Acácias2” não foi classificada no mês de agosto (tal como na legenda alterada 1), o que pode ser justificado pela falta de separabilidade da classe (confirmada pela análise da divergência transformada em agosto), levando o classificador a não classificar a não conseguir classificar esta categoria (Tabelas 22 e 23).

Relativamente à exatidão do produtor (EP) do mês de agosto, a classe melhor classificada foi a “Artificial2” (100%), seguida da classe “Florestas2” (71,43%). No mês de março, o valor máximo foi obtido na classe “Artificial2” (83,33%), seguido das classes “Agrícolas2” e “Água2” (ambas com resultados na ordem dos 77%).

Os resultados da exatidão do utilizador (EU) foram mais reduzidos nas classes “Florestas2” (37,5%) e “Artificial2” (42,86%) em agosto e “Meios Naturais 2” (45,45%) em março. Os melhores resultados globais pertencem às classes “Meios Naturais2” (100%), “Água2” (92,31%) e “Agrícolas2” (88,89%) em agosto. Embora o mês de agosto tenha os melhores resultados globais, percentualmente março, tem melhores valores médios, destacando-se a classe “Agrícolas2” (73,91%) e “Acácias2”, “Florestas2” e “Artificial2” (todas com cerca de 65%).

Em relação ao índice Kappa, os resultados confirmaram as classificações obtidas na EU, surgindo os melhores índices nas classes “Meios Naturais2” ($K= 1$), “Água2” ($K= 0,91$) e “Agrícolas2” ($K= 0,87$) como as classes com melhores valores globais.

A classe “Acácias2” apenas foi classificada no mês de março, com um Kappa satisfatório (0,58%), sendo este bastante superior ao obtido pelo mesmo classificador no mês correspondente da legenda anterior (Legenda alterada 1).

4.3.2.3 Máquinas de Vetores de Suporte

Tal como na legenda anterior (legenda original) a aplicação do classificador das máquinas de vetores de suporte (MVS) registou os piores resultados globais, entre os classificadores usados, com uma exatidão global (EG) de 44,7% e Kappa de 0,35 (Razoável) em agosto e EG de 47,18% e Kappa de 0,38 (Razoável) em março. A classe “Resinosas1” não foi classificada, muito provavelmente devido ao facto da reduzida separabilidade da espécie com outras classes, que fez com que o classificador não tivesse conseguido associar pixels a esta classe (Tabelas 22 e 23).

A utilização do classificador das máquinas de vetores de suporte obteve os piores resultados gerais na globalidade dos classificadores utilizados (tal como nas duas legendas anteriores), com uma exatidão global (EG) de 42,98% e Kappa (K) de 0,31 (Razoável) em agosto (inferior à legenda alterada 1) e EG de 53,26% e Kappa de 0,43 em março (Bom) (superior à legenda alterada 1).

Relativamente aos resultados da exatidão do produtor (EP), esta tem resultados relevantes apenas nas classes “Agriculturas” (81,82%), “Acácias2” (73,91%) e “Água2” (72,22%) em março. São de salientar os resultados muito baixos registados pelos “Meios Naturais2” em março (5,56%) e “Agriculturas2” em agosto (16,67%).

Em relação aos valores obtidos pela exatidão do utilizador (EU), podem-se destacar os resultados bastante positivos da classe “Água2” em agosto (100%) e “Artificial2” em março (78,57%). A legenda alterada 2 obteve melhores valores gerais no mês de março, sendo que apenas as classes “Florestas2” e “Acácias2” registaram EU abaixo dos 50%.

Os resultados de Kappa estão em harmonia com os registados pela EU, aparecendo as classes “Água2” em agosto (K= 1) e “Artificial2” em março (K= 0,75) com os melhores resultados.

A classe “Acácias2” obteve resultados fracos em ambos os meses (K= 0,20 em agosto e K= 0,34 em março), estando no entanto novamente subjacente o melhor mapeamento da espécie na época de floração (março).

Tabela 22 - Matriz de confusão da legenda alterada 2 - agosto de 2005.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agriculturas2	81,82	85,71	0,83	44	88,89	0,87	16,67	27,27	0,14
Acácias2	91,3	58,33	0,49	0	0	0	33,33	35	0,20
Florestas2	40	100	1	71,43	37,5	0,23	57,14	41,38	0,28
Água2	100	100	1	66,67	92,31	0,91	38,89	100	1
Meios Naturais2	77,78	60,87	0,54	55,56	100	1	61,11	57,89	0,50
Artificial2	83,33	93,75	0,93	100	42,86	0,32	50	32,14	0,19
EG	77,42			55,26			42,98		
Kappa	0,73			0,46			0,31		

Tabela 23 - Matriz de confusão da legenda alterada 2 - março de 2007.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agriculturas2	94,44	89,47	0,88	77,27	73,91	0,68	81,82	60	0,51
Acácias2	95,24	76,92	0,72	73,91	65,38	0,58	73,91	45,95	0,34
Florestas2	76,19	84,21	0,81	56	66,67	0,58	24	35,29	0,19
Água2	94,44	89,47	0,88	77,78	70	0,65	72,22	54,17	0,46
Meios Naturais2	88,89	94,12	0,93	27,78	45,45	0,36	5,56	50	0,42
Artificial2	77,78	100	1	83,33	65,22	0,59	61,11	78,57	0,75
EG	87,72			66,13			53,26		
Kappa	0,85			0,59			0,43		

4.3.2.4 Comparação de resultados

Os resultados globais de exatidão global (EG) e Kappa dos classificadores nos meses de agosto e março estão discriminados na tabela 24 de forma a permitir uma comparação de resultados entre estes.

O classificador da máxima verosimilhança obteve os melhores resultados no conjunto dos classificadores utilizados, sendo que o mês de março registou os melhores resultados globais (EG = 87,72% e K= 0,85, praticamente o mesmo resultado da legenda anterior no mesmo período). Os restantes classificadores obtiveram resultados substancialmente inferiores à MV, destacando-se no entanto o Kappa das RNA em março (K=0,59), como moderadamente positivo. Denota-se (como nas legendas anteriores utilizadas) os melhores resultados obtidos no mês de março.

Tabela 24 - Valores de exatidão global e Kappa- legenda alterada 2.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
EG	77,42	55,26	42,98	87,72	66,13	53,26
Kappa	0,73	0,46	0,31	0,85	0,59	0,43

A figura 29 representa as classes de ocupação do solo utilizadas na legenda alterada 2, em março de 2007, pelo classificador MV que registou os melhores valores globais de classificação.

No mês de agosto a classe “Acácias2” registou a maior área de ocupação (1259 km²), seguida pelas classes “Meios Naturais2” (777 km²) e “Agrícolas2” (520 km²). Mais uma vez, é evidente a confusão espectral entre as classes “Acácias2” e “Florestas2”, que leva a que a *Acacia dealbata* tenha uma ocupação muito superior à real (Tabela 25).

Relativamente ao mês de março, a classe “Florestas2” tem a maior área de ocupação (1256 km²), seguida pelas “Acácias2” (560 km²) e “Agrícolas2” (487 km²) (Tabela 25).

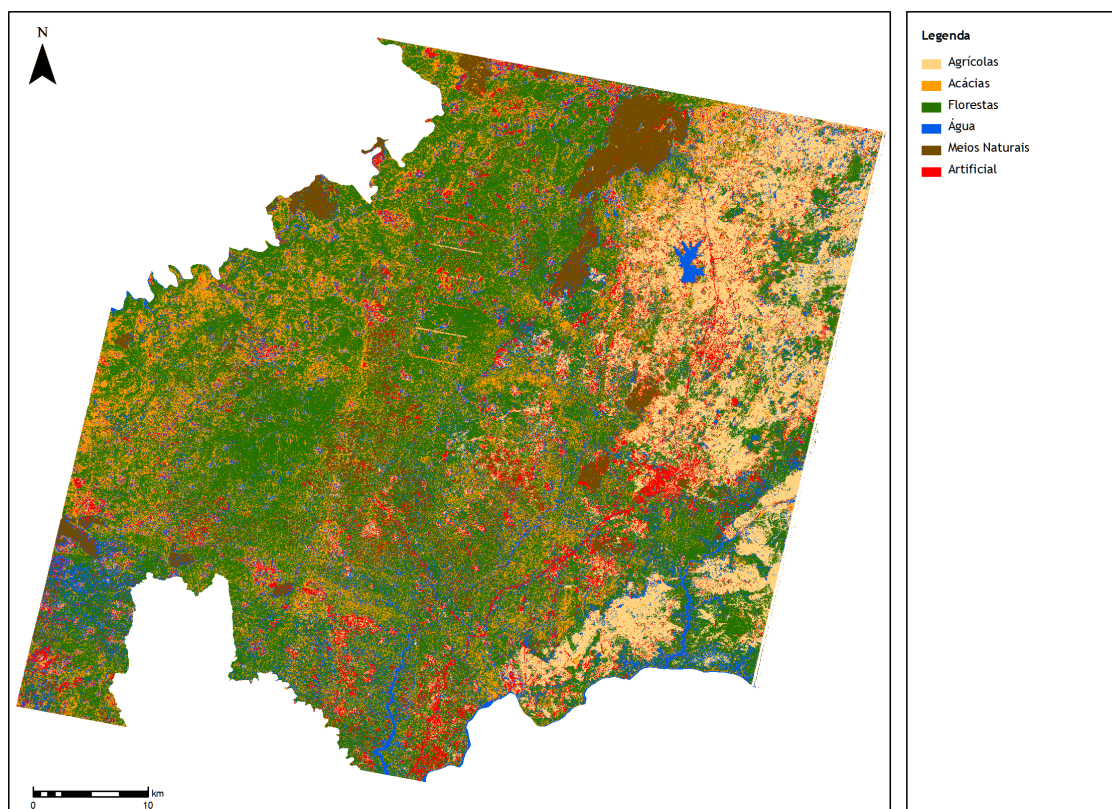


Figura 29 - Mapa de ocupação do solo da legenda alt2, classificador da MV - março de 2007.

Tabela 25 - Área (km²) das classes da legenda alt2, classificador da MV.

Classe	Agosto	Março
Agrícolas	520,8	487,9
Acácias	1259,0	560,7
Florestas	268,0	1256,8
Água	170,3	324,0
Meios Naturais	777,8	334,8
Artificial	215,2	247,0

De seguida, apresentam-se as figuras respeitantes à exatidão do produtor (EP), exatidão do utilizador (EU) e Kappa condicional (KC) de cada classe da legenda (Figuras 30, 31 e 32).

Relativamente à EP, o classificador MV regista melhores resultados nas classes “Agrícolas2”, “Acácias2”, “Florestas2”, “Água2” e “Meios Naturais2”, sendo ultrapassado apenas na classe “Artificial2” pelo classificador das RNA.




Figura 30 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.

Analisando a figura 31, que diz respeito à exatidão do utilizador, as classes “Agrícolas2”, “Acácias2”, “Florestas2”, “Água2” (*ex equo* com MVS) e “Artificial2” são melhores classificadas com o classificador MV. A classe “Meios Naturais2” registou melhor classificação nas RNA, enquanto que a “Água2” obteve o máximo nas MVS (*ex equo* com a MV).




Figura 31 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.

Os resultados do índice Kappa são semelhantes aos registados pela EU, realçando-se os K= 1 nas classes “Florestas2” (MV em agosto), “Água2” (MV e MVS em agosto), “Meios Naturais2” (RNA em agosto) e “Artificial2” (MV em março).

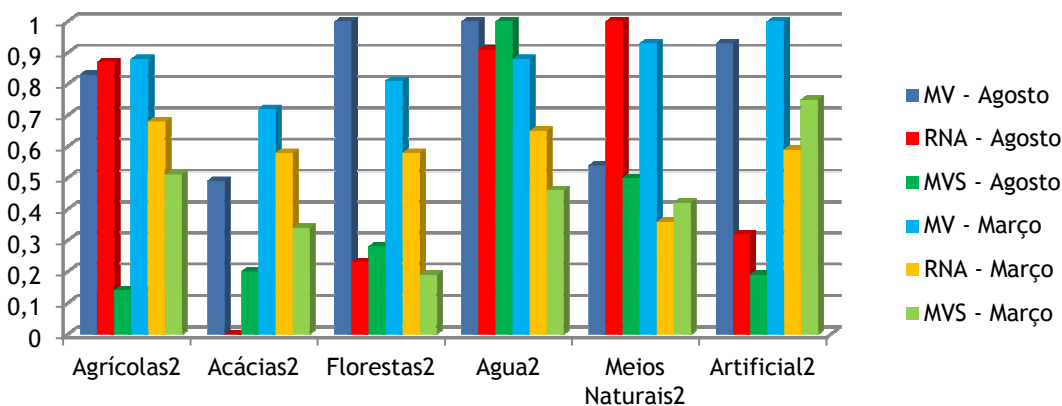


Figura 32 - Determinação do índice Kappa dos classificadores, legenda alt2 - agosto de 2005 e março de 2007.

4.4 Legenda alterada 3 - 5 classes

4.4.1 Separabilidade espectral

Na legenda alterada 3, onde se procurou inferir sobre a influência da classe “Meios Naturais”, caracterizada por uma elevada variabilidade espectral, sobre as restantes classes, conclui-se que tal como se tem vindo a observar, a influência era mínima, não incrementando com isso a separabilidade entre as classes, embora venha a ter consequências positivas na classificação como veremos mais adiante.

Tabela 26 - Valores de separabilidade da legenda alterada 3 - agosto de 2005.

Divergência Transformada

Classe	Agrícolas3	Acácias3	Florestas3	Água3	Artificial3
Agrícolas3	0				
Acácias3	1,84	0			
Florestas3	1,83	1,24	0		
Água3	1,93	1,92	1,96	0	
Artificial3	1,65	1,97	2,00	1,90	0

>1,9 Efetiva separabilidade
 1,7 - 1,9 Moderada separabilidade
 <1,7 Falta separabilidade

Tabela 27 - Valores de separabilidade da legenda alterada 3 - março de 2007.

Classe	Agrícolas3	Acácias3	Florestas3	Água3	Artificial3
Agrícolas3	0				
Acácias3	1,29	0			
Florestas3	1,78	1,74	0		
Água3	1,99	1,98	1,98	0	
Artificial3	2,00	2,00	1,99	1,97	0

>1,9 Efetiva separabilidade
 1,7 - 1,9 Moderada separabilidade
 <1,7 Falta separabilidade

4.4.2 Classificação

As tabelas 28 e 29 representam os resultados gerais e por categoria, da aplicação dos classificadores da máxima verosimilhança (MV), redes neuronais artificiais (RNA) e máquinas de vetores de suporte (MVS) à legenda alterada 3.

4.4.2.1 Máxima Verosimilhança

Os resultados gerais do classificador MV no mês de março foram praticamente idênticos aos da legenda anterior (legenda alterada 2) no mesmo período, com uma exatidão global (EG)

de 88,54% e Kappa (K) de 0,86 (Excelente). No mês de agosto, os resultados globais são ligeiramente inferiores aos do mês de março, com uma EG de 83,96% e Kappa de 0,79 (Muito bom), sendo superiores aos registados na legenda anterior (Legenda alterada 2).

Relativamente à exatidão do produtor (EP), esta é praticamente semelhante entre as classes do mês de agosto e de março, havendo a maior discrepância na classe “Florestas3” (EP= 48% em agosto e EP= 76,19% em março).

Em relação à classificação pela exatidão do utilizador (EU), essa foi globalmente positiva na quase totalidade das classes em ambos os meses (o pior resultado foi registado pela classe “Acácias3” em agosto). São de destacar as classes “Florestas3” e “Água3” em agosto (EU= 100% em ambas) e a classe “Artificial3” em março (EU= 100%).

Analisando os resultados da EP e EU, denota-se a melhoria da capacidade de classificação das outras classes pela remoção da classe “Meios Naturais”, o que confirma a elevada abrangência espectral da classe.

Comparando os valores de Kappa entre os meses de agosto e março, existe uma quase equivalência no número de classes com valores máximos de Kappa para cada mês (2 classes em agosto e 3 classes em março). As classes “Florestas3” e “Água3” com K=1 em agosto têm o maior valor entre os meses analisados, sendo que as restantes classes “Artificial3” (K=1) “Agrícolas3” (K=0,87) e “acácia3” (K=0,75) têm valores máximos em março.

O índice Kappa para a classe “Acácias3” é superior em março (K=0,75), realçando a boa separabilidade entre espécies na época de floração da *Acacia dealbata*, a qual saiu reforçada com a remoção da classe “Meios Naturais”.

4.4.2.2 Redes Neurais Artificiais

O classificador das redes neuronais artificiais (RNA) obteve o segundo melhor resultado na classificação da legenda alterada 3 (sendo apenas suplantado pela MV), com uma exatidão global (EG) de 63,5% e Kappa de 0,54 em agosto (Bom) e EG de 72,64% e Kappa de 0,65 (Muito bom) em março. É de salientar que os resultados globais subiram em ambos os meses, realçando-se a melhoria da classificação com a remoção da classe “Meios Naturais” (Tabelas 28 e 29).

Relativamente à exatidão do produtor (EP) do mês de agosto, a classe melhor classificada foi a “Artificial3” (100%), seguida da classe “Florestas3” (71,43%). No mês de março, o valor máximo foi obtido na classe “Artificial3” (83,33%), seguido das classes “Agrícolas3” e “Água3” (ambas com resultados na ordem dos 77%).

A exatidão do produtor (EP) foi particularmente positiva nas classes “Artificial3” em agosto e março (94,44% e 77,78% respetivamente), “Acácias3” em agosto (76,19%), e “Água3” em março (83,33%).

Relativamente à exatidão do utilizador (EU) os melhores valores gerais foram obtidos no mês de março, realçando-se “Água3” (93,75%) e “Acácias3” (84,62%), sendo que o valor mais baixo pertence à classe “Florestas3” (53,85%). No mês de agosto é de destacar a classificação de “Agrícolas3” (100%).

A classificação do índice Kappa realça os valores da EU, com o mês de março a registar as melhores classificações. Nesse mês apenas a classe “Florestas” tem um Kappa abaixo dos 0,70, sendo o valor máximo registado pela classe “Água3” (K= 0,92).

A classe “Acácias3” foi melhor classificada no mês de março (mês da floração), com um Kappa de 0,80, sendo este um aumento assinalável relativamente à legenda anterior (Legenda alterada 2, tinha um K=0,58 em março).

4.4.2.3 Máquinas de Vetores de Suporte

O classificador das máquinas de vetores de suporte (MVS) registou os piores resultados no conjunto dos classificadores utilizados (tal como em todas as legendas adotadas até ao momento) em ambos os meses. No mês de agosto, a exatidão global (EG) foi de 39,58% e o Kappa de 0,24 (Razoável), sendo que no mês de março a EG foi de 63,20% e o Kappa de 0,54 (Bom).

Os resultados da exatidão do produtor (EP) foram especialmente baixos no mês de agosto. Apesar de o mês de março apresentar a EP mais baixa (20% na classe “Florestas3”), este possui valores elevados nas classes “Agricultoras3” (81,82%), “Acácias3” (78,26%) e “Artificial3” (77,78%).

Relativamente à exatidão do utilizador (EU) são de destacar os resultados das classes “Água3” em agosto (78,57%) e “Artificial3” em março (82,35%). O mês de março obteve melhores valores gerais, com todas as classes a registarem classificações acima dos 50%.

Os resultados de Kappa são na maioria das classes baixos, apenas se destacando as classes “Água3” em agosto (K= 0,74), “Artificial3” e “Agricultoras3” em março (0,70 e 0,61 respetivamente).

A classe “Acácias3” obteve resultados fracos em ambos os meses (K= 0,10 em agosto e K= 0,40 em março), denotando-se no entanto uma melhor classificação da espécie na época de floração (março).

Tabela 28 - Matriz de confusão da legenda alterada 3 - agosto de 2005.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agricultora3	90,91	86,96	0,84	55,56	100	1	22,22	30,77	0,15
Acácias3	96,65	66,67	0,57	76,19	55,17	0,43	28,57	30	0,10
Florestas3	48	100	1	28,57	60	0,49	47,62	38,46	0,21
Água3	100	100	1	66,67	75	0,69	61,11	78,57	0,74
Artificial3	94,44	85	0,82	94,44	54,84	0,44	38,89	30,43	0,14
EG		83,96			63,54			39,58	
Kappa		0,79			0,54			0,24	

Tabela 29 - Matriz de confusão da legenda alterada 3 - março de 2007.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícola3	94,44	89,47	0,87	72,73	80	0,75	81,82	69,23	0,61
Acácias3	100	80,77	0,75	47,83	84,62	0,80	78,26	52,94	0,40
Florestas3	76,19	88,89	0,86	84	53,85	0,40	20	50	0,35
Agua3	94,44	89,47	0,87	83,33	93,75	0,92	66,67	63,16	0,56
Artificial3	77,78	100	1	77,78	77,78	0,73	77,78	82,35	0,79
EG	88,54			72,64			63,20		
Kappa	0,86			0,65			0,54		

4.4.2.4 Comparação de resultados

O resultado das classificações exatidão global (EG) e Kappa obtidos pelos classificadores da máxima verosimilhança (MV), redes neurais artificiais (RNA) e máquinas de vetores de suporte (MVS), estão registados na tabela 30.

Da análise da tabela, é notório que o classificador MV obteve melhores resultados em ambos os meses, seguido pelas RNA e finalmente pelas MVS. O classificador MV teve melhores resultados no mês de março (K=0,86), evidenciando a melhor classificação geral deste mês, em todas as legendas adotadas.

Tabela 30 - Valores de exatidão global e Kappa - legenda alterada 3.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
EG	83,96	63,54	39,58	88,54	72,64	63,2
Kappa	0,79	0,54	0,24	0,86	0,65	0,54

A figura 33 representa a ocupação do solo obtida pelo classificador com melhores resultados globais (MV de março de 2007).

No mês de agosto a classe “Acácias3” tem a maior área de ocupação (1328 km²), seguida pela classe “Agrícolas3” (817 km²) e “Artificial3” (451 km²) (Tabela 31).

Relativamente ao mês de março, as classes com maior ocupação do solo são as de “Florestas3” (1302 km²), “Acácias3” (765 km²) e “Agrícolas3” (495 km²) (Tabela 31).

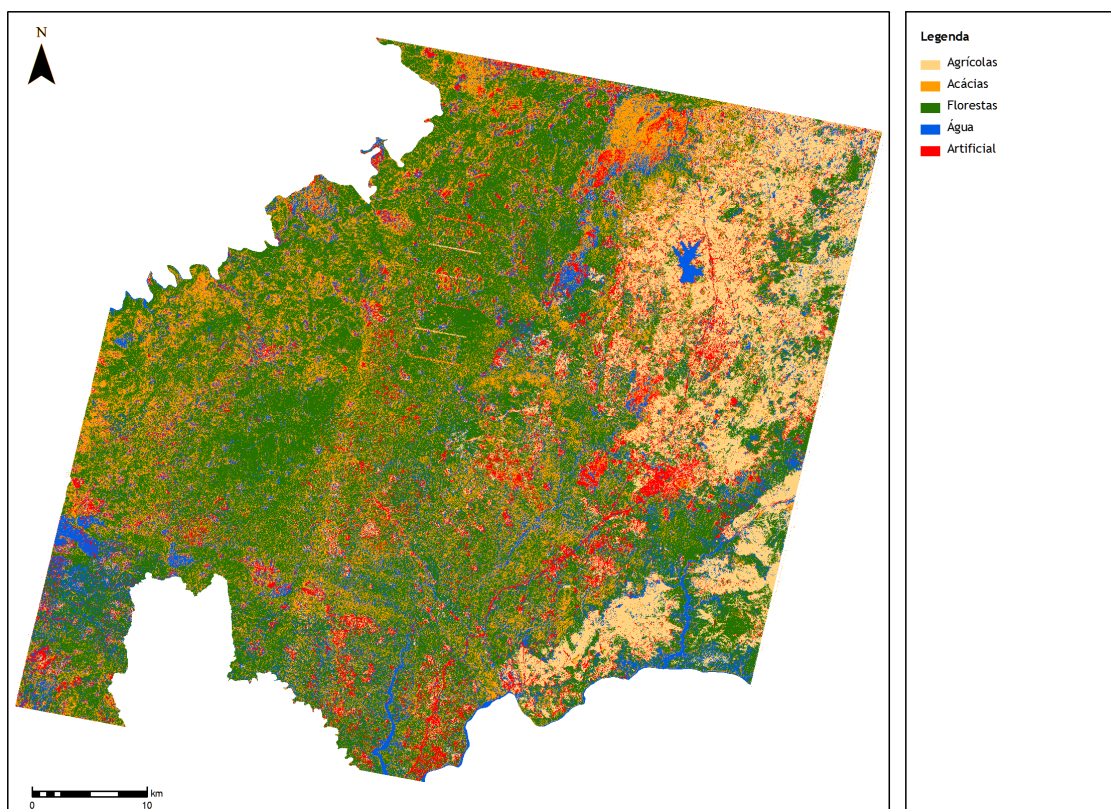


Figura 33 - Mapa de ocupação do solo da legenda alt3, classificador da MV - março 2007.

Tabela 31 - Área (km²) das classes da legenda alt3, classificador da MV.

Classe	Agosto	Março
Agrícolas	817,6	495,5
Acácias	1328,9	765,
Florestas	432,5	1302,3
Água	180,4	368,6
Artificial	451,9	279,2

Para uma melhor percepção dos valores de exatidão do produtor (EP), exatidão do utilizador (EU) e Kappa (K), apresentam-se as figuras 34, 35 e 36.

Relativamente à EP, o classificador MV regista melhores resultados nas classes “Agrícolas3”, “Acácias3”, “Água3” e “Artificial3” (*ex equo* com as RNA), sendo ultrapassado apenas na classe “Florestas3” pelo classificador das RNA. É de destacar as EP de 100% registadas pelas classes “Acácias3” (MV em março) e “Água3” (MV em agosto).

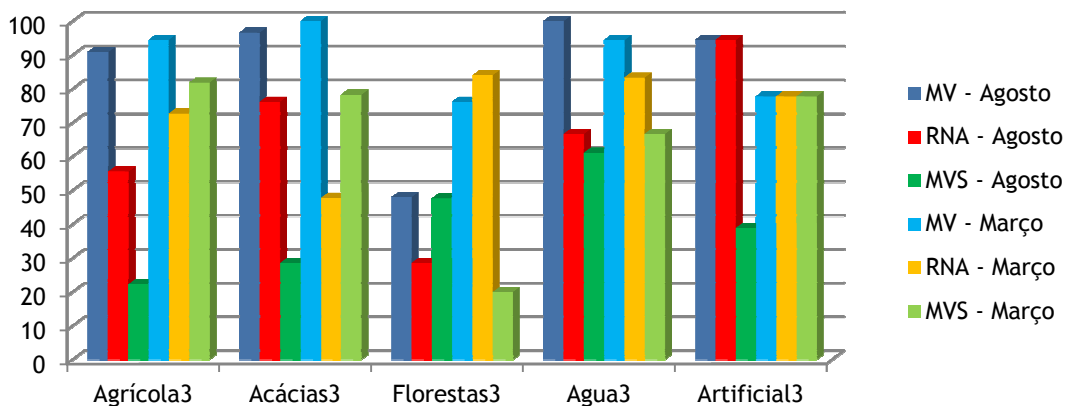


Figura 34 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.

Na exatidão do utilizador (EU), existe uma maior variação de resultados máximos pelos classificadores. Assim sendo as RNA têm a maior EU na classificação da classe “Agrícolas3”, as MVS na classificação das “Acácias3” e a MV na classificação das “Florestas3”, “Água3” e “Artificial3”.

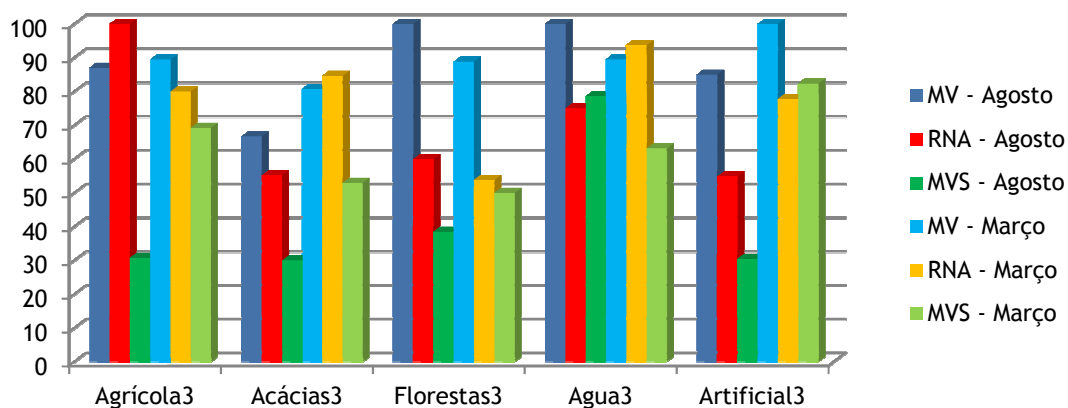


Figura 35 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.

Os resultados do índice Kappa são semelhantes aos registados pela EU, realçando-se os K= 1 nas classes “Agrícolas3” (RNA em agosto), “Florestas3” (MV em agosto), “Água3” (MV em agosto) e “Artificial3” (MV em março).




Figura 36 - Determinação do índice Kappa dos classificadores, legenda alt3 - agosto de 2005 e março de 2007.

4.5 Legenda alterada 4 - 4 classes

4.5.1 Separabilidade espectral

Na legenda alterada 4, onde se procurou estudar a aplicabilidade de imagens ASTER para cartografia de grandes classes genéricas de ocupação do solo, retiraram-se de acordo com a tabela 32 e 33 as seguintes conclusões da análise da separabilidade espectral intra-classe para os meses de março e agosto:

- a separabilidade é menor em agosto, com a classe “Artificial4” a ter falta de separabilidade com “Agriculturas4”, existindo também moderada separabilidade entre as classes “Florestas4” e “Agriculturas4” por um lado, e “Água4” e “Florestas4” por outro. Neste último caso, apenas a existência de sítios de treino mal classificados ou a sua ocorrência em áreas de transição entre ambas as tipologias poderá justificar tal falta de separabilidade;
- a separabilidade é melhor no mês de março, havendo apenas falta de separabilidade entre a classe “Florestas4” e “Agriculturas4”. Esta fraca separabilidade poderá ser justificada pela presença de sítios de treino mal classificados, pela sua ocorrência em áreas de transição entre ambas as tipologias, ou ainda pela larga abrangência espectral de cada classe.

Tabela 32 - Valores de separabilidade da legenda alterada 4 - agosto de 2005

Divergência Transformada

Classe	Agriculturas4	Florestas4	Água4	Artificial4
Agriculturas4	0			
Florestas4	1,73	0		
Água4	1,92	1,85	0	
Artificial4	1,65	1,96	1,90	0

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

Tabela 33 - Valores da separabilidade da legenda alterada 4 - março de 2007

Divergência Transformada

Classe	Agriculturas4	Florestas4	Água4	Artificial4
Agriculturas4	0			
Florestas4	1,46	0		
Água4	1,99	1,97	0	
Artificial4	2,00	1,98	1,97	0

>1,9	Efetiva separabilidade
1,7 - 1,9	Moderada separabilidade
<1,7	Falta separabilidade

4.5.2 Classificação

De seguida são apresentados os resultados gerais e por classe da classificação da legenda alterada 4, através dos classificadores da máxima verosimilhança (MV), redes neuronais artificiais (RNA) e máquinas de vetores de suporte (MVS) (Tabelas 34 e 35).

4.5.2.1 Máxima Verosimilhança

O classificador da máxima verosimilhança obteve melhores resultados globais no mês de agosto (*ex equo* com as RNA), com uma exatidão global de 79,17% e Kappa de 0,7 (Muito bom) e no mês de março, com uma EG de 92,45% e Kappa de 0,89 (Excelente).

A exatidão do produtor (EP) teve valores muito bons no mês de março (todas as classes acima do 90%), embora no mês de agosto esses valores sejam claramente inferiores, denotando-se uma confusão espectral entre as classes, o que vem ao encontro do que foi analisado na divergência transformada.

A exatidão do utilizador (EU) registou bons valores em todas as classes de ambos os meses, menos a classe “Artificial4” do mês de agosto (58,64%). Este baixo valor já era esperado, pois a classe na análise da divergência transformada tinha uma fraca separabilidade com a classe “Agrícolas4”, que pode ter levado à fraca capacidade de classificação.

Relativamente ao Kappa (K), este obteve valores em consonância com a análise da EU, sendo que o Kappa mais baixo foi o da classe “Artificial4” em agosto. Os valores mais elevados foram registados pelas classes “Artificial4”, “Água4” e “Florestas4” no mês de março (K= 0,93, K= 0,93, K= 0,92 respetivamente).

4.5.2.2 Redes Neuronais Artificiais

O classificador das redes neuronais artificiais (RNA) obteve resultados globais e por classe no mês de agosto, semelhantes ao classificador MV no mesmo período de tempo, ou seja exatidão global (EG) de 79,19% e Kappa de 0,7 (Muito bom). Por sua vez, o mês de março registou valores ligeiramente superiores de Kappa (K= 0,78) e de EG (84,90%).

A exatidão do produtor (EP) do mês de agosto foi totalmente igual à classificação do MV no mesmo mês. No mês de março os valores da EP foram bastante positivos, indo do mínimo de 72,22% da classe “Artificial4” até ao máximo de 93,75% da classe “Florestas4”.

Relativamente à exatidão do utilizador (EU) e Kappa (K), os resultados foram globalmente positivos em ambos os meses, sendo que a classe “Artificial4” registou o Kappa (0,49) e EU (58,62%) mais reduzidos.

4.5.2.3 Máquinas de Vetores de Suporte

O classificador das máquinas de vetores de suporte (MVS) registou os resultados mais baixos na globalidade dos classificadores utilizados, obtendo uma exatidão global (EG) de 60,42% e Kappa (K) de 0,41 (Bom) no mês de agosto e uma EG de 65,09% e Kappa de 0,43 (Bom) em março.

Os valores de exatidão do produtor (EP) apenas são de destacar na classe “Florestas4”, com uma classificação na ordem dos 95% em ambos os meses.

Em relação à exatidão do utilizador (EU) salientam-se os bons resultados obtidos nas classes “Artificial4” (100%) no mês de março e “Água4” no mês de agosto e março (81,82% e 90% respetivamente).

Relativamente aos Kappa das classes da legenda, estes estão em consonância com os resultados obtidos pela classificação da exatidão do utilizador, com as classes “Artificial4” (K= 1) em março e “Água4” em agosto e março (K= 0,78 e K= 0,88 respetivamente) a registarem os melhores resultados.

Tabela 34 - Matriz de confusão da legenda alterada 4 - agosto de 2005.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícolas4	55,56	83,33	0,79	55,56	83,33	0,79	16,67	25	0,08
Florestas4	88,1	88,1	0,79	88,1	88,1	0,79	95,24	74,07	0,54
Água4	66,67	92,31	0,91	66,67	92,31	0,91	50	81,82	0,78
Artificial4	94,44	58,62	0,49	94,44	58,62	0,49	33,33	31,58	0,16
EG	79,17			79,17			60,42		
Kappa	0,7			0,7			0,41		

Tabela 35 - Matriz de confusão da legenda alterada 4 - março de 2007.

Classe	MV			RNA			MVS		
	EP	EU	KC	EP	EU	KC	EP	EU	KC
Agrícolas4	90,91	83,33	0,79	81,82	85,71	0,82	45,45	76,92	0,71
Florestas4	91,67	95,65	0,92	93,75	84,91	0,72	95,83	58,23	0,24
Água4	94,44	94,44	0,93	77,78	87,5	0,85	50	90	0,88
Artificial4	94,44	94,44	0,93	72,22	81,25	0,77	22,22	100	1
EG	92,45			84,9			65,09		
Kappa	0,89			0,78			0,43		

4.5.2.4 Comparação de resultados

Da análise da tabela 36, que indica os índices globais dos classificadores utilizados na legenda alterada 4, salientam-se os melhores resultados em todos os classificadores em março, relativamente a agosto. É de realçar os melhores resultados obtidos pelo classificador MV no conjunto dos dois meses (embora em agosto o resultado das RNA seja semelhante ao da MV).

Tabela 36 - Valores de exatidão global e Kappa- legenda alterada 4.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
EG	79,17	79,17	60,42	92,45	84,9	65,09
Kappa	0,7	0,7	0,41	0,89	0,78	0,43

O melhor resultado global obtido pelo classificador utilizado encontra-se representado na figura 37 (MV em março), na qual se pode observar a distribuição das classes da legenda alterada 4.

No mês de agosto, os classificadores MV e das RNA registaram os mesmos valores globais de Kappa e exatidão global, no entanto a distribuição das áreas de ocupação do solo não foi semelhante. Assim sendo no classificador MV, a classe com maior área de ocupação foi a “Florestas4” (2004 km²), seguido pela “Agrícolas4” (513 km²), “Água4” (404 km²) e “Artificial4” (289 km²). Relativamente ao classificador das RNA, o ordenamento das classes foi bastante similar ao classificador MV (apenas a troca de “Artificial4” por “Água4”), apesar de as áreas de ocupação terem sido ligeiramente diferentes (“Florestas4” = 2096 km²; “Agrícolas” = 492 km²; “Artificial4” = 431 km²; “Água4” = 191 km²) (Tabela 37).

Relativamente ao mês de março, a classe com maior ocupação é a “Florestas4” (1609 km²), seguida pela “Agrícolas4” (1049 km²), “Artificial4” (314 km²) e “Água4” (237 km²) (Tabela 37).

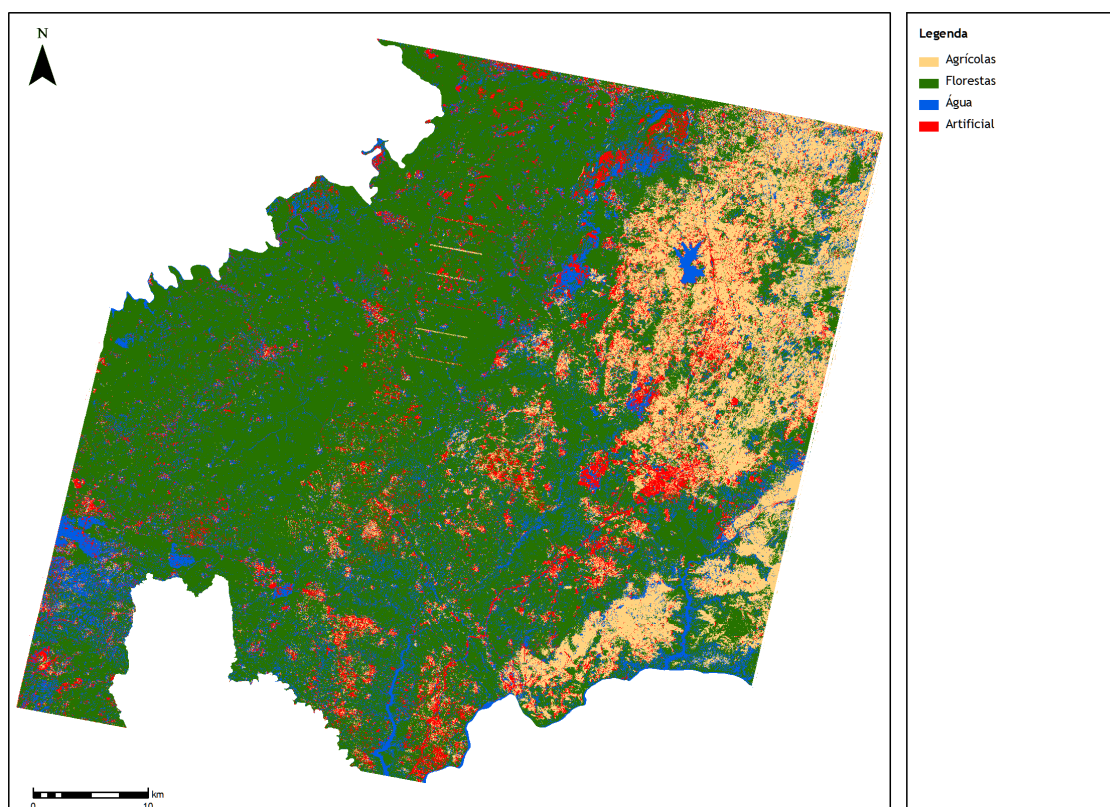


Figura 37 - Mapa de ocupação do solo da legenda alt4, classificador da MV - março 2007.

Tabela 37 - Área (km²) das classes da legenda alt4.

	Agosto		Março
	MV	RNA	MV
Agrícolas	513,7	492,3	1049,9
Florestas	2004,1	2096,3	1609,9
Água	404,4	191,4	237,3
Artificial	289,0	431,4	314,2

As figuras 38, 39 e 40 representam, respetivamente, os resultados da exatidão do produtor (EP), exatidão do utilizador (EU) e Kappa condicional (KC) de cada classe utilizada na legenda.

Relativamente à EP existe uma distribuição de melhores resultados pelos diferentes classificadores utilizados. A MV registou melhores resultados nas classes “Agrícolas4”, “Água4” e “Artificial4” (*ex equo* com RNA), as MVS na classe “Florestas4” e as RNA na “Artificial4” (*ex equo* com a MV).

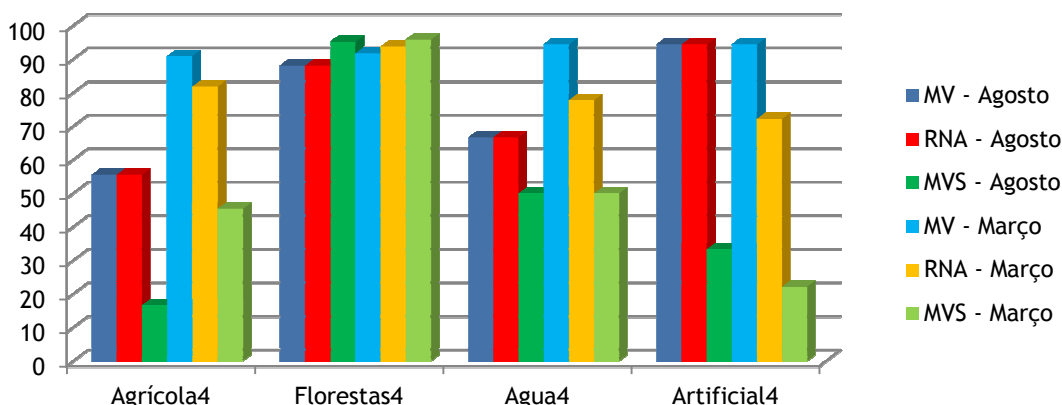


Figura 38 - Avaliação do índice de exatidão do produtor dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.

Analisando a exatidão do utilizador, existe novamente uma distribuição de melhores resultados pelos classificadores utilizados, sendo que a classe “Agrícolas4” é melhor classificada pelas RNA, “Florestas4” e “Água4” pelo classificador da MV e “Artificial4” pelas MVS.




Figura 39 - Avaliação do índice de exatidão do utilizador dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.

Os resultados do índice Kappa são em tudo iguais aos obtidos na EU anteriormente analisada, destacando-se pela positiva o K=1 da classe “Artificial4” (MVS em março) e pela negativa as classes “Agrícolas4” (K= 0,08 pelas MVS em agosto) e “Artificial4” (K= 0,16 pelas MVS em agosto).




Figura 40 - Determinação do índice Kappa dos classificadores, legenda alt4 - agosto de 2005 e março de 2007.

4.6 *Acacia dealbata* - síntese comparativa

Para uma melhor avaliação dos resultados obtidos pela *Acacia dealbata* nas diversas legendas e classificadores, sintetizaram-se os resultados no presente sub-capítulo, onde se analisarão os índices Kappa de todas as legendas (4.6.1) e as áreas de ocupação resultantes da classificação (4.6.1).

4.6.1 Comparação de índices Kappas

Os valores do índice Kappa para a classe de referência do trabalho de projeto, *Acacia dealbata* Link, na legenda original, são superiores no classificador das RNA em agosto (K=0,61) e pela MV em março (K=1). Denota-se a influência da floração na cartografia da “Acácias” no mês de março, com o valor de Kappa de março a quase duplicar o registrado em agosto.

Na legenda alterada 1 os melhores resultados são obtidos no classificador MV para o mês de março (K=0,81), seguido pelas MVS também em março (K= 0,60). Os valores de Kappa são sempre superiores no mês de março comparados com os de agosto, sendo de realçar a não classificação da classe em agosto, muito provavelmente devido à falta de separabilidade da *Acacia dealbata* com outras espécies (“Folhosas1” e “Resinosas1”).

A *Acacia dealbata*, na legenda alterada2, foi melhor classificada no mês de março, destacando-se o Kappa obtido pelo classificador MV (K=0,72). Relativamente à legenda anterior (Legenda alterada 1), realça-se a troca de posições entre os valores de Kappa das RNA e das MVS, passando o Kappa das RNA de 0,30 para os 0,58 e o Kappa das MVS de 0,60 para 0,34. A classe não foi classificada pelo classificador RNA em agosto (tal como na legenda alterada 1), o que pode ser explicado pela reduzida separabilidade com a classe “Florestas2” nesse período.

Relativamente à legenda alterada 3, a classes “Acacias3” foi melhor classificada em agosto pelo classificador MV, sendo que em março (pela primeira vez em todas as legendas utilizadas até ao momento), a melhor classificação foi obtida pelo classificador das RNA.

Fazendo uma síntese global dos resultados de Kappa obtidos pela classe “Acácias”, constata-se que os melhores resultados foram registados no mês de março em todas as legendas, com o classificador MV a destacar-se, pois obteve melhor Kappa na legenda original, legenda alterada 1 e legenda alterada 2, sendo que na legenda alterada 3 o melhor registo surgiu nas RNA. Por sua vez, o valor máximo de Kappa é o da legenda original (K=1), sendo com essa legenda que se classificaram povoamentos de *Acacia dealbata* com maior precisão na área de estudo.

Tabela 38 - Valores de Kappa da classe “Acácias”.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
Original	0,54	0,61	0,22	1	0,53	0,15
Alterada 1	0,53	0	0,20	0,81	0,39	0,60
Alterada 2	0,49	0	0,20	0,72	0,58	0,34
Alterada 3	0,57	0,43	0,10	0,75	0,80	0,40

4.6.2 Análise de áreas de ocupação

Analisando os resultados das áreas de ocupação de *Acacia dealbata* pelos diferentes classificadores nas legendas adoptadas, desde logo se destaca a heterogeneidade de áreas obtidas, assim como as áreas quase sempre superiores obtidas no mês de agosto (mês com os índices Kappa mais baixos).

No mês de agosto, registou-se uma diversidade de valores de área, indo deste um mínimo de 36,7 km² nas RNA da legenda alterada 2 até aos 1883 km² (K=0) das MVS da legenda alterada 3 (K=0,1). A média de valores totais de ocupação foi de 952 km², sendo que para a legenda original foi de 722 km², na legenda alterada 1 de 495 km², na legenda alterada 2 de 1046 km² e na legenda 3 de 1543 km².

Relativamente ao mês de março, a área de ocupação obtida com o melhor resultado de Kappa (K=1 na MV da legenda original) foi de 247 km², sendo que no Kappa mais reduzido (K=0,15 nas MVS da legenda original) foi de 349 km². A média de área total foi de 525 km², passando para os 357 km² na legenda original, 222 km² na legenda alterada 1, 821 km² na legenda alterada 2 e 701 km² na legenda alterada 3. O aumento das áreas de ocupação de “Acácias” no classificador da MV, desde a legenda original, pode ser explicado pela confusão espectral existente pela junção de várias classes de folhosas e resinosas nas restantes legendas, que levou o classificador a qualificar outras espécies como “Acácias”.

Tabela 39 - Área (km²) da classe “Acácias”.

	agosto de 2005			março de 2007		
	MV	RNA	MVS	MV	RNA	MVS
Original	760,5	178,6	1229,4	247,7	475,4	349,5
Alterada 1	887,4	226,1	374,2	436,9	219,4	12,4
Alterada 2	1259,0	36,7	1844,7	560,7	462,8	1441,8
Alterada 3	1328,9	1418,5	1883,5	765,6	1008,4	330,8

As figuras 41 a 48 indicam a distribuição geográfica de manchas de *Acacia dealbata* na zona de estudo. Da análise das figuras, podem-se retirar as seguintes conclusões:

- as ocupações são quase sempre superiores no mês de agosto;
- embora exista uma distribuição heterogénea pelos diferentes classificadores, existem áreas que são quase sempre classificadas, ficando essas a oeste, noroeste e numa zona central da zona de estudo;
- as zonas com os índices Kappa superiores (março) têm ocupações de “Acácias” com pouca continuidade espacial, tendo no entanto algumas zonas com densidades bastante elevadas.

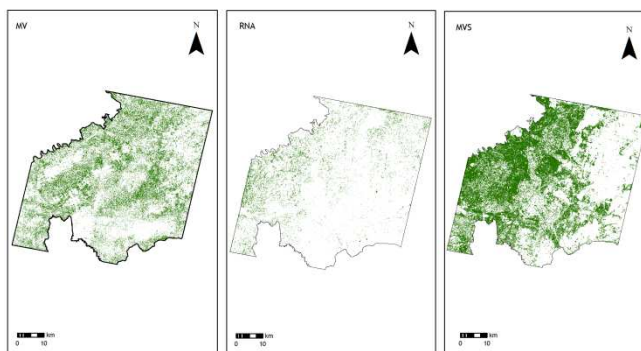


Figura 41 - Mapa de ocupação de *Acacia dealbata* da legenda original - Agosto de 2005.

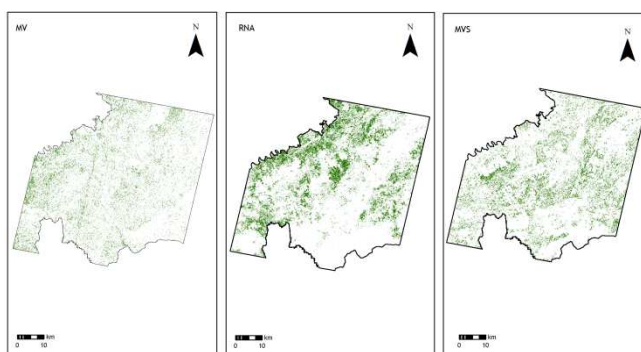


Figura 42 - Mapa de ocupação de *Acacia dealbata* da legenda original - Março de 2007.

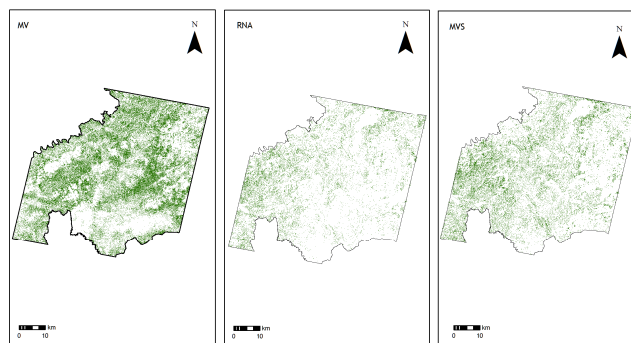


Figura 43 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 1 - Agosto de 2005.

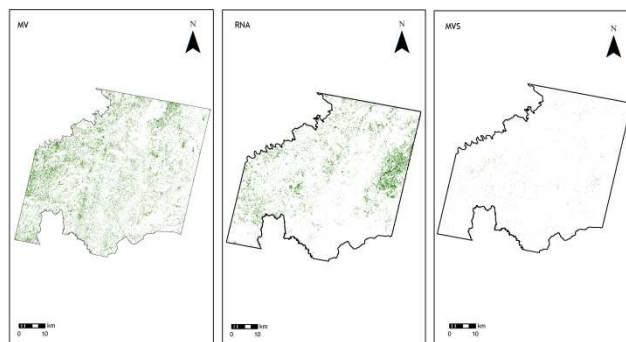


Figura 44 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 1 - Março de 2007.

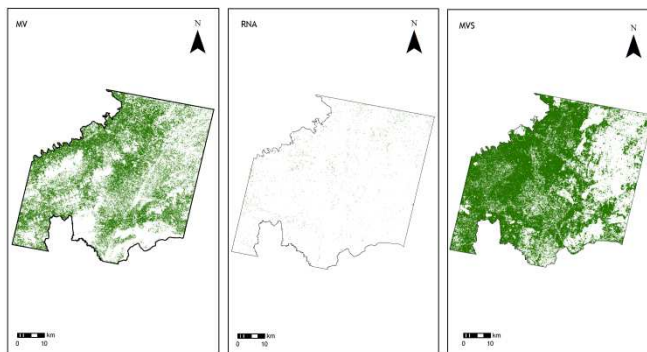


Figura 45 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 2 - Agosto de 2005.

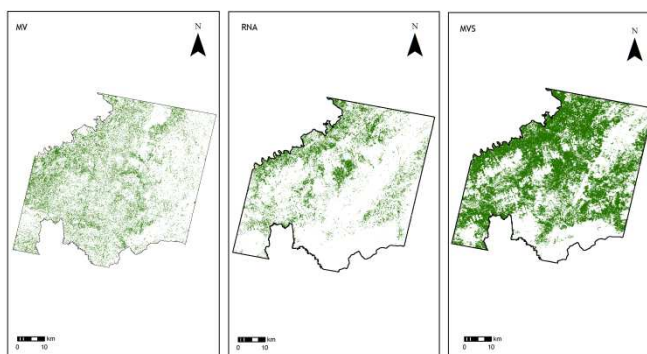


Figura 46 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 2 - Março de 2007.

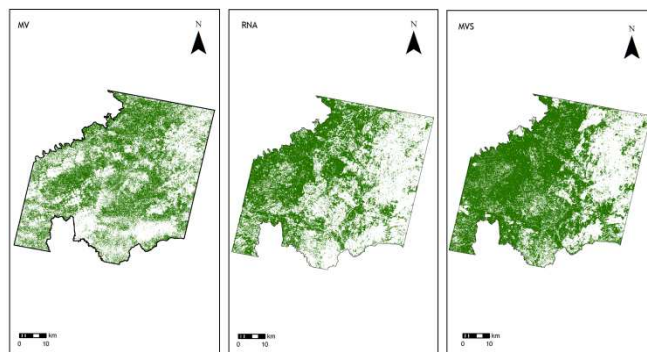


Figura 47 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 3 - Agosto de 2005.

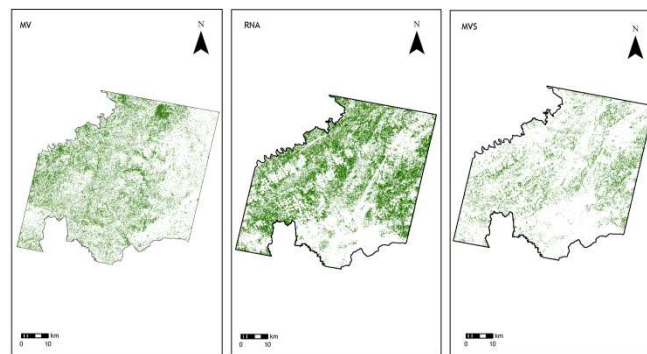


Figura 48 - Mapa de ocupação de *Acacia dealbata* da legenda alterada 3 - Março de 2007.

5. Conclusões

O principal objetivo da dissertação de Mestrado foi explorar e avaliar o potencial de imagens multiespectrais ASTER obtidas em dois períodos distintos do ano para cartografia de *Acacia dealbata* Link. Para tal foi em primeira instância analisada a separabilidade espectral de diferentes nomenclaturas de ocupação do solo, ajustadas às características biofísicas da área de estudo. Posteriormente foram testados, avaliados e comparados diferentes classificadores paramétricos (MV) e não-paramétricos (MVS e RNA) para análise dos padrões espectrais existentes nas imagens ASTER. Finalmente foram produzidos mapas de ocupação do solo que incluem as manchas de *Acacia dealbata*, para uma área do Distrito de Castelo Branco (Região centro sul de Portugal continental).

Globalmente a classificação efetuada nas várias legendas e épocas do ano demonstrou que a utilização de imagens multiespectrais ASTER para cartografia de *Acacia dealbata* na região centro sul de Portugal continental, pode constituir uma solução técnica interessante, viável e de baixo custo para o diagnóstico e uma contínua avaliação e monitorização da ocorrência e expansão da espécie na zona de estudo.

O resultado das classificações globais demonstrou que o classificador da máxima verosimilhança obteve melhores resultados em todas as legendas utilizadas. A imagem de março de 2007, obteve melhores resultados de separabilidade em todas as legendas utilizadas. O melhor Kappa geral foi obtido na legenda alterada 3 ($K=0,86$). Os restantes classificadores (RNA e MVS) demonstraram uma precisão global bastante baixa (RNA sempre abaixo de $K=0,65$; MVS sempre abaixo de $K=0,54$).

Ao nível da classificação das classes que não sofreram alterações em todas as nomenclaturas utilizadas, a cartografia de “Agrícolas” obteve bons resultados em ambos os meses com a MV [agosto - $0,74 \text{ (alt1)} \leq K \leq 0,84 \text{ (original, alt3)}$; março - $0,82 \text{ (original)} \leq K \leq 1 \text{ (alt1)}$] e no mês de agosto com as RNA ($0,86 \leq K \leq 1$). A classe “Artificial” obteve melhores resultados no mês de agosto com o classificador MV [$0,82 \text{ (alt3)} \leq K \leq 1 \text{ (original)}$] e no mês de março com os classificadores MV [$0,93 \text{ (original)} \leq K \leq 1 \text{ (alt1, alt2, alt3)}$] e RNA [$0,59 \text{ (alt2)} \leq K \leq 0,79 \text{ (alt1)}$]. A classe “Água” obteve bons resultados em agosto e março com a MV [agosto - $1 \leq K \leq 1$; março $0,86 \text{ (original, alt3)} \leq K \leq 0,87 \text{ (alt1, alt2)}$], em ambos os meses com as RNA [agosto - $1 \leq K \leq 1$; março $0,65 \text{ (original)} \leq K \leq 0,91 \text{ (alt2)}$] e no mês de agosto com a legenda alt2 das MVS ($K=1$).

Relativamente às classes que foram sendo alteradas, agregadas ou eliminadas nas diferentes legendas, a classe “Meios Naturais” registou resultados de realçar com a MV no mês de março [$0,75 \text{ (original)} \leq K \leq 0,93 \text{ (alt3)}$]. A classe “Resinosas” alcançou bons resultados na MV no mês de março [$0,76 \text{ (alt1)} \leq K \leq 0,79 \text{ (original)}$]. A classe “Castanheiro-Carvalho” que apenas se utilizou na legenda original, obteve bons resultados nos classificadores da MV ($K=0,92$) e RNA ($K=1$) do mês de março. A classe “Azinheira-Sobreiro” que foi apenas usada na legenda original registou bons resultados com o classificador MV em ambos os meses (agosto $K=1$ e março $K=0,89$). A classe “Folhosas” foi utilizada na legenda alt2, com os melhores resultados a serem registados pelo classificador da MV em agosto e março (agosto $K=0,83$ e março $K=0,78$). A classe “Florestas” registou excelente precisão com o classificador da MV em agosto ($1 \leq K \leq 1$) e boa precisão no mês de março [$0,81 \text{ (alt2)} \leq K \leq 0,86 \text{ (alt3)}$].

A cartografia do principal alvo do trabalho, a *Acacia dealbata*, obteve melhores resultados em todos os classificadores e legendas utilizadas no mês de março, daí se podendo concluir que a influência da época de floração é extremamente importante num mapeamento eficaz da espécie. O valor mais elevado de precisão foi obtido pelo classificador da MV ($K=1$) na legenda original, podendo-se também destacar o resultado da MV na legenda alt1 ($K=0,81$), das RNA na legenda alt3 ($K=0,8$), da MV na legenda alt3 ($K=0,75$) e na legenda alt2 ($K=0,72$).

O grau de aplicabilidade e fiabilidade da cartografia de *Acacia dealbata* obtida por imagens ASTER pode ser interessante e pertinente, especialmente se for utilizado o classificador da máxima verosimilhança, tendo o melhor Kappa ($K=1$) sido classificado pelo classificador, resultando numa área de ocupação de cerca de 250 km^2 . Embora se tenham obtido resultados animadores na classificação das imagens, há que ter em conta que muito provavelmente a cartografia não representará totalmente a ocupação de *Acacia dealbata* no território, pois a resolução espacial das imagens ASTER é de 15 metros, podendo assim, não serem mapeados pequenas ocupações pela espécie. No entanto estes resultados poderão servir de auxílio às autoridades competentes, para uma melhor identificação e monitorização de áreas infestadas por esta espécie invasora, ficando desde já referenciadas zonas de potencial infestação, nomeadamente a oeste, noroeste e zona central da zona de estudo.

Devido à pobre separabilidade espectral existente entre algumas categorias de vegetação utilizadas (especialmente entre diferentes tipos de cobertura florestal), os resultados dos classificadores MV, RNA e MVS poderão ser potencialmente incrementados se forem aumentadas a quantidade e qualidade dos sítios de treino e se forem integrada no esquema de classificação

informação espacial auxiliar como a altitude, declive, distância a linhas de água, tipo de solo e litologia, como exemplos mais usados.

Analisando o segundo objetivo do estudo, que era procurar estudar a aplicabilidade de imagens ASTER para mapeamento de grandes classes genéricas de ocupação do solo, retiraram-se as seguintes conclusões:

- o resultado da precisão global obteve bons resultados com os classificadores MV e RNA, com mais destaque para o mês de março. O Kappa mais elevado foi registado na MV de março (K=0,89) e RNA de março (K=0,78).
- na classificação por classe de ocupação do solo, todas as classes obtiveram excelentes classificações. A classe “Agriculturas” registou a melhor classificação com as RNA em março (K=0,82). As restantes classes foram melhores classificadas com o classificador da MV em março (“Florestas” - K= 0,92; “Água” - K= 0,93; “Artificial” - K=0,93).

Da leitura dos resultados fica perceptível a real aplicabilidade de imagens ASTER na classificação de classes genéricas de ocupação do solo, pois estas não estão tão limitadas por áreas inferiores a 15 metros, o que incrementa a precisão global e por classe.

Apesar dos resultados animadores obtidos pela utilização de imagens multiespectrais ASTER, é notório o seu *handicap* na separabilidade espectral entre diferentes manchas de vegetação, nomeadamente entre folhosas e resinosas, assim como pela sua resolução espacial (área mínima cartografada), que poderá não mapear locais onde a ocupação não seja superior a 225 m² (15*15 metros). Estudos futuros para monitorização e mapeamento da *Acacia dealbata*, poderão ser efetuados com recurso a sensores hiperespectrais, sendo estes considerados por Huang (2009), como a fonte atualmente mais utilizada para estudos de invasoras. Tal como já referenciado no decurso desta Tese, a solução óptima (embora cara) para uma cartografia fiável e precisa de *Acacia dealbata* (ou qualquer outro tipo de vegetação) passaria pelo uso de imagens hiperespectrais de alta resolução espacial.

Apesar das suas limitações a nível espectral, as imagens de muita alta resolução espacial, poderão constituir uma abordagem importante no mapeamento de *Acacia dealbata*, existindo já estudos com resultados animadores, como o de Gil *et al.* (2011) em que foi cartografado *Pittosporum undulatum* (uma espécie invasora extremamente agressiva na Região Autónoma dos Açores) com recurso a imagens IKONOS.

Referências Bibliográficas

- Abe, S., 2005. *Support Vector Machines for Pattern Classifications*. Kobe: Springer.
- Abrams, M., Hook, S. e Ramachandran, B., 1999. *Aster User Handbook* Version 2. Pasadena: NASA/Jet Propulsion Laboratory.
- Adler-Golden, S.M., et al., 1999. Atmospheric correction for shortwave spectral imagery based on MODTRAN4. *SPIE Proceeding Imaging Spectrometry V*, 3753, 61-69.
- Aggarwal S., 2003. Principles of Remote Sensing Satellite. In: *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*, 7-11 Julho 2003 Dehra Dun. 23-38.
- Agrawal G. e Sarup J., 2011. Comparison of QUAC and FLAASH Atmospheric Correction Modules on EO-1 Hyperion Data of Sanchi. *International Journal of Advanced Engineering Sciences and Technologies*, 4(1), 178 - 186.
- Aplin, P., Atkinson P.M. e Curran P.J., 1997. Fine spatial resolution satellite sensors for the next decade. *International Journal of Remote Sensing*, 18(18), 3873-3881.
- Boser, B.E., Guyon, I.M. e Vapnik, V., 1992. A training algorithm for optimum margin classifiers. In: *Fifth Annual Workshop on Computational Learning Theory*, Pittsburgh.
- Brooks, M.L., et al., 2004. Effects of invasive alien plants on fire regimes. *BioScience*, 54(7), 677-688.
- Chuvieco, E., 1995. *Fundamentos de Teledetección Espacial*. 2º ed. Madrid: Ediciones Rialp.
- Cobbing, B.L., 2007. *The use of Landsat ETM imagery as a suitable data capture source for alien acacia species for the WFW programme*. Tese (Mestrado). Rhodes University.
- Cohen J., 1960. A coefficient of agreement for nominal scales. *Educational and psychological measurement*. 20(1), 37-46.
- Congalton, R. G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*. 49 (12), 1671-1678.
- Congalton, R. G., e Green, K., 1999. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. New York: Lewis Publishers.
- Costa, A. L. 1976. A acção de produtos fitocidas no combate ao acacial infestante. In: *II Simpósio Nacional de Herbologia*, Oeiras. 239-252.
- Cronk, Q.C.B. e Fuller, J.L., 2001. *Plant Invaders: The Threat to Natural Ecosystems*. London: Earthscan Publications.
- Crosta, A.P., 1993. *Processamento digital de imagens de sensoriamento remoto*. Campinas: IG/Unicamp.
- Deacon, H.J., 1991. Historical background of invasions in the Mediterranean region of Southern Africa. In: R.H. Groves e F. Di Castri, ed. *Biogeography of Mediterranean Invasions*. Cambridge: University Press, 51-58.
- Erbek, F.S., Özkan, C. e Taberner, M., 2004. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. *International Journal of Remote Sensing*, 25 (9), 1733-1748.
- Fernandes, M.J.S.M., 2008. *Recuperação ecológica de áreas invadidas por Acacia dealbata Link no vale do rio Gerês: um trabalho de sísifo?* Tese (Mestrado). Universidade de Trás-os-Montes e Alto Douro.
- Florenzano, T.G., 2002. *Imagens de satélites para estudos ambientais*: São Paulo: Oficina de Textos.
- Foody, G.M., 2000. mapping land cover from remotely sensed data with a softened feedforward neural network classification. *Journal of Intelligent and Robotic Systems*, 29(4), 433-449.
- Fuller, D.O., 2005. Remote detection of invasive Melaleuca trees (*Melaleuca quinquenervia*) in South Florida with multispectral IKONOS imagery. *International Journal of Remote Sensing*. 26(5), 1057-1063.
- Gil, A., et al., 2011. Assessing the effectiveness of high resolution satellite imagery for vegetation mapping in small islands protected areas. *Journal of Coastal Research*, 64, 1663-1667.
- Han, J., et al., 2002. Comparison of neuro-fuzzy, neural network and maximum likelihood classifiers for land cover classification using ikonos multispectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 41, 3471-3473.
- Haykin, S., 1999. *Neural networks: a comprehensive foundations*. 2º ed. New Jersey: Prentice Hall.
- Heywood, V. H., 1989. Patterns, extents and modes of invasions by terrestrial plants. In J.A. Drake, et al., ed. *Biological Invasions: a Global Perspective*. Chichester: John Wiley and Sons, 31-60.
- Huang, C, Asner, G., 2009. Applications of remote sensing to alien invasive plant studies. *Sensors*, 9, 4869-4889.
- Huang, C., Davis, L.S. e Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23 (4), 725-749.
- IBGE, 2001. *Introdução ao processamento digital de imagens*. Rio de Janeiro: IBGE.
- IUCN, 2000. Guidelines for the Prevention of biodiversity loss caused by alien invasive species. *51st Meeting of the IUCN Council*.
- Jensen, J., 1996. *Introductory Digital Image Processing: A Remote Sensing Perspective*. Englewood Cliffs, New Jersey: Prentice-Hall.
- Joshi, C., Leeuw, J. e van Duren, I.C., 2004. Remote sensing and GIS applications for mapping and spatial modelling of invasive species. In: *ISPRS, XX ISPRS congress*, 12-23 Julho 2004, Istanbul. 669-677.
- Laba, M., et al., 2008. Mapping invasive wetland plants in the Hudson River National Estuarine research reserve using QuickBird satellite imagery. *Remote Sensing Environment*, 112, 286-300.
- Landis, J.R. e Koch, G.G., 1977. The measurement of observer agreement for categorical data. *Biometrics*, 33, 159-174.
- Lawes, R.A. e Wallace, J.F., 2008. Monitoring an invasive perennial at the landscape scale with remote sensing. *Ecological Management and Restoration* 9 (1), 53-59.
- Le Floch, E., 1991. Invasive Plants of the Mediterranean Basin. In: R.H. Groves e F. Di Castri, ed. *Biogeography of Mediterranean Invasions*. Cambridge University: Press, 67- 80.
- Le Wang. Invasive species spread mapping using multi-resolution remote sensing data. *Remote Sensing and Spatial Information Sciences*, 38 (B2).
- Lockwood J.L, Hoopes, M.F e Marchetti, P., 2006. *Invasion Ecology*. I Ed. Oxford. Blackwell Publishing.
- Loureiro, M.L.D.S., 2008. *Exploração das características espectrais de imagens ikonos para caracterização da ocupação do solo: comparação de classificadores*. Tese (Mestrado). Universidade Técnica de Lisboa, Instituto Superior Técnico.
- Mack, M. C. e D'Antonio, C. M. 1998. Impacts of biological invasions on disturbance regimes. *Trends in Ecology and Evolution*, 13(5), 195-198.
- Marchante, H., Marchante, E. e Freitas, H., 2005. Invasive plant species in Portugal: an overview. In: S. Brunel ed. *International Workshop on Invasive Plants in Mediterranean Type Regions of the World*, 25-27 Maio 2005 Montpellier. Council of Europe Publishing, 99-103.

- Marchante, H.S.D.C., 2001. Invasão de ecossistemas dunares portugueses por *Acacia*: uma ameaça para a biodiversidade nativa. Tese (Mestrado). Universidade de Coimbra.
- Masocha, M. e Skidmore, A.K., 2011. Integrating conventional classifiers with a GIS expert system to increase the accuracy of invasive species mapping. *International Journal of applied Earth Observation and Geoinformation*, 13 (3), 487 - 494.
- Matos, J., 2008. *Fundamentos de Informação Geográfica*. 5ª ed. atualizada e aumentada, LIDEL - Edições técnicas, Lda.
- May, B.M. e Attiwill, P.M., 2003. Nitrogen-fixation by *Acacia dealbata* and changes in soil properties 5 years after mechanical disturbance or slash-burning following timber harvest. *Forest Ecology and Management*, 181(3), 339-355.
- Moreira, M.A., 2007. *Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação*. 3ª ed. atualizada e ampliada, Universidade Federal de Viçosa: Editora UFV.
- Naylor, R. L. 2000. The economics of alien species invasions. In H. A. Mooney e R. J. Hobbs, ed. *Invasive Species in a Changing World*. Washington DC: Island Press, 241-259.
- Novo, E.M.L.M. e Ponzoni, F. J., 2001. *Introdução ao Sensoriamento Remoto*. São José dos Campos: Instituto Nacional de pesquisas Espaciais, Divisão de Sensoriamento Remoto.
- Paiva, J. 1999. *Acacia Mill. In: S. Castroviejo, ed. Flora Iberica, Plantas Vasculares de la Península Ibérica e Islas Baleares*. Madrid: Real Jardín Botánico, 11-25.
- Parker, I.M., et al., 1999. Impact: toward a framework for understanding the ecological effects of invaders. *Biological Invasions*, 1 (22), 3-19.
- Pereira, M.C., e Caetano, M., 2005. Use of very high spatial resolution satellite imagery for thematic applications: a review. In: *XXI International Symposium on Remote Sensing of Environment*, 20-24 Junho 2005, Saint Petersburg.
- Pimentel, D., Zuniga, R. e Morrison, D., 2005. Update on the environmental and economic costs associated with alien-invasive species in the United States. *Ecological Economics*, 52(3), 273-288.
- Plantier, T.A.L.A., 2006. *Análise de padrões espectrais e espaciais de imagens de muito grande resolução espacial para caracterização da ocupação do solo*. Tese (Mestrado). Universidade Técnica de Lisboa.
- Pu, R., et al., 2008. Invasive species change detection using artificial neural networks and CASI hyperspectral imagery. *Environmental Monitoring and Assessment*, 140, 15-32.
- Qiu, F. e Jensen J.R., 2004. Opening the black box of neural networks for remote sensing image classification. *International Journal of Remote Sensing*, 25(9), 1749-1768.
- Reichard, S.E., 1996. Prevention of invasive plant introductions on national and local levels. In: J.O. Luken e J.W. Thiere, ed. *Assessment and management of plant invasions*. New York: Springer-Verlag, 215-227.
- Ribera, M.A. e Boudouresque C.F., 1995. Introduced marine plants, with special reference to macroalgae: mechanisms and impact. In: F.E. Round and D.J. Chapman, ed. *Progress in Phycological Research*. Biopress Ltd, 217-268.
- Richards, J.A. e Jia, X., 1999. *Remote Sensing Digital Image Analysis*. 4ª ed. Berlim: Springer.
- Rocha, F.J.P.S.P., 2002. *Integração de dados estatísticos na classificação de imagens de satélite*. Tese (Mestrado). Universidade Técnica de Lisboa, Instituto Superior Técnico.
- Schowengerdt, R.A., 1983. *Techniques for Image Processing and Classification in Remote Sensing*. Tucson: University of Arizona Press.
- Shigesada, N. e Kawasaki, K., 1997. *Biological Invasions: theory and practice*. Oxford: University of Oxford Press.
- Shippert P., 2002. Introduction to hyperspectral image analysis. Research Systems.
- Sudheer, K.P., et al., 2010. Artificial neural network approach for mapping contrasting tillage practices. *Remote Sensing* (23), 579-590.
- Tsai, F., Chou, M.J. e Wang H.H., 2005. Texture analysis of high resolution satellite imagery for mapping invasive plants. In: *Geoscience & Remote Sensing Symposium*, 29-29 July 2005 Seoul. 3024-3027.
- Ustin, S.L., et al., 2002. Hyperspectral remote sensing for invasive species detection and mapping. In: *International Geoscience and Remote Sensing Symposium*, 24-28 June 2002 Toronto. 1658-1660.
- Van der Meer, et al., 2002. New Environmental RS systems. In: A. K. Skidmore, ed. *Environmental modelling with GIS and RS*. London: Taylor and Francis, 26-51.
- Vapnik, V.N., 1999. *The Nature of Statistical Learning Theory*. USA. 2ª ed. New York: Springer-Verlag.
- Vega J., M., e Isabel M.P.M., 2010. *Guía didáctica de teledetección y medio ambiente red nacional de teledetección ambiental*. Madrid: Red Nacional de Teledetección Ambiental.
- Venugopal, G., 1998. Monitoring the effects of biological control of water hyacinths using remotely sensed data: a case study of Bangalore, India. *Singapore Journal of Tropical Geography*, 19(1), 92-105.
- Viana, H., e Aranha, J., 2005. Identificação de áreas ocupadas por *Acacia dealbata* recorrendo a imagens Landsat ETM+. Estudo efetuado nos Distritos de Coimbra, Guarda e Viseu. In: *5.º Congresso Florestal Nacional*, 16-19 Maio 2005 Viseu.
- Vieira, C.A.O., 2000. *Accuracy of remotely sensing classification of agricultural crops: a comparative study*. Tese (PhD). University of Nottingham.
- Watzlawick, L.F., Kirchner, F. F. e Madruga, P.R.A., 2003. Avaliação de classificação digital em imagens de vídeo multiespectral utilizando matriz confusão. *Revista de Ciências Exatas e Naturais*, 5 (1), 47-57.
- Williamson, M., 1996. *Biological Invasions*. London: Chapman & Hall.
- Xie, Y., Sha, Z. e Yu, M., 2008. Remote sensing imagery in vegetation mapping: a review. *Journal of Plant Ecology*, 1(1), 9-23.
- Yang, X. 2011. Parameterizing Support Vector Machines for Land Cover Classification. *Photogrammetric Engineering & Remote Sensing*. 7 (1), 27-37.
- Zhang, L., Dawes, W. R., e Walker, G.R., 1999. Predicting the effect of vegetation changes on catchment average water balance., *Cooperative Research Center for Catchment Hydrology*, Technical Report 99.

Diplomas Jurídicos Consultados

Decreto-Lei 565/99 de 21 de Dezembro
(Regula a introdução na natureza de espécies não indígenas da flora e fauna)

Lei n.º 1951 de 9 de março de 1937
(estabelece as bases para a proibição ou sementeira de eucaliptos ou de acácias).