

**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ**  
**ΤΜΗΜΑ ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ & ΜΗΧΑΝΙΚΩΝ**  
**ΥΠΟΛΟΓΙΣΤΩΝ**



**Διπλωματική Εργασία**

***Αλγόριθμοι ταξινόμησης δεδομένων υπερφασματικής απεικόνισης  
για την ανίχνευση , τμηματοποίηση και ταυτοποίηση  
χαρακτηριστικών διαγνωστικής σημασίας***

Αδάμος Αθανάσιος

Εξεταστική Επιτροπή : Μπάλας Κωνσταντίνος (Επιβλέπων)  
Ποταμιάνος Αλέξανδρος  
Ζερβάκης Μιχάλης

Χανιά , Οκτώβριος 2006

## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία περιλαμβάνει μία συνοπτική ανασκόπηση βασικών θεμάτων φασματοσκοπίας και φασματικής απεικόνισης, και εφαρμογών τους σε διάφορα επιστημονικά πεδία είτε μέσω της τηλεπισκόπησης είτε σε περιβάλλον εργαστηρίου.

Παρουσιάζεται μία εκτενής βιβλιογραφική ανάλυση σε θέματα υπερφασματικής απεικόνισης και τεχνικών ταξινόμησης των υπερφασματικών δεδομένων. Επίσης εξετάζονται διάφοροι τρόποι εξαγωγής χαρακτηριστικών των υπερφασματικών δεδομένων (feature extraction) και ελαχιστοποίησης της διαστατικότητας τους (dimensionality reduction, band selection), κάποιοι μέθοδοι συλλογής φασμάτων και η σπουδαιότητά τους, καθώς και τεχνικές Spectral Unmixing.

Ακολουθεί αναλυτική περιγραφή των βασικότερων αλγορίθμων που χρησιμοποιούνται σήμερα στην ταξινόμηση υπερφασματικών δεδομένων, σύγκρισή τους και περιγραφή των πλεονεκτημάτων και μειονεκτημάτων τους.

Τέλος υλοποιούνται κάποιοι απ'τους αλγορίθμους σε περιβάλλον Matlab οι οποίοι θα δέχονται στην είσοδό τους μία υπερφασματική εικόνα με την μορφή υπερφασματικού κύβου και θα παρουσιάζουν στην έξοδο την αντίστοιχη ταξινομημένη ψευδοχρωματική εικόνα.

Στα συμπεράσματα γίνεται λόγος για εναλλακτικές τεχνικές ταξινόμησης υπερφασματικών δεδομένων, όπως ανάπτυξη του παραλληλισμού, τεχνικές ελεύθερης κατανομής και χρήση Support Vector Machines, καθώς και εναλλακτικές προσεγγίσεις αναπαράστασης των υπερφασματικών δεδομένων.

# ΠΕΡΙΕΧΟΜΕΝΑ

|  |    |
|--|----|
| Εισαγωγή.....σελίδα 7  | 7  |
| <b>Κεφάλαιο 1<sup>ο</sup> Εισαγωγή στη φασματοσκοπία</b>                       |    |
| 1.1 Εισαγωγή.....  | 9  |
| 1.2 Η ηλεκτρομαγνητική ακτινοβολία.....  | 9  |
| 1.3 Το ηλεκτρομαγνητικό φάσμα.....   | 10 |
| 1.4 Αλληλεπίδραση ακτινοβολίας και ύλης – Φασματοσκοπία.....                   | 12 |
| 1.4.1 Απορρόφηση – Εκπομπή.....  | 12 |
| 1.4.2 Φθορισμός – Φωσφορισμός.....   | 13 |
| 1.4.3 Σκέδαση.....   | 14 |
| 1.4.3.1 Είδη σκέδασης.....   | 14 |
| • Σκέδαση Rayleigh.....  | 14 |
| • Σκέδαση Raman.....   | 15 |
| • Σκέδαση Mie.....   | 15 |
| • Σκέδαση Stokes και Anti-Stokes.....  | 15 |
| • Σκέδαση Brillouin.....   | 15 |
| 1.5 Είδη φασματοσκοπίας.....   | 16 |
| 1.6 Ενδεικτικές εφαρμογές φασματοσκοπίας.....                                  | 16 |
| 1.7 Η φασματοσκοπία στην ιατρική.....  | 18 |
| 1.7.1 Οπτική Βιοψία.....   | 18 |
| 1.8 Τηλεπισκόπηση (Remote Sensing).....  | 19 |
| 1.8.1 Τρόποι τηλεπισκόπησης.....   | 20 |
| 1.9 Πολυφασματικές εικόνες.....  | 21 |
| <b>Κεφάλαιο 2<sup>ο</sup> Υπερφασματική απεικόνιση (Hyperspectral Imaging)</b> |    |
| 2.1 Εισαγωγή.....  | 23 |
| 2.2 Υπερφασματικοί Αισθητήρες.....   | 24 |
| 2.2.1 Χωρική Ανάλυση.....  | 25 |
| 2.2.2 Φασματική Ανάλυση.....   | 25 |
| 2.3 Φασματικές Υπογραφές (Spectral Signatures).....                            | 25 |
| 2.4 Υπερφασματική vs Πολυφασματική Απεικόνιση.....                             | 26 |
| 2.5 Εφαρμογές Υπερφασματικής απεικόνισης.....                                  | 29 |
| <b>Κεφάλαιο 3<sup>ο</sup> Επεξεργασία των υπερφασματικών δεδομένων</b>         |    |
| 3.1 Εισαγωγή.....  | 30 |
| 3.2 Προεπεξεργασία.....  | 30 |
| 3.2.1 Ατμοσφαιρική Διόρθωση.....   | 30 |
| 3.2.2 Γεωμετρική Διόρθωση.....   | 31 |
| 3.2.3 Image Registration.....  | 31 |
| 3.3 Ελαχιστοποίηση δεδομένων (Data Reduction).....                             | 32 |
| 3.3.1 Εξαγωγή Χαρακτηριστικών (Feature Extraction).....                        | 33 |
| 3.3.2 Ο χώρος χαρακτηριστικών (Feature Space).....                             | 33 |
| 3.4 Μαθηματικό Υπόβαθρο.....   | 35 |
| 3.4.1 Στατιστική.....  | 35 |
| 3.4.2 Τυπική Απόκλιση (Standard Deviation).....                                | 35 |
| 3.4.3 Διακύμανση (Variance).....   | 36 |
| 3.4.4 Συμμεταβλητότητα (Covariance).....                                       | 36 |
| 3.4.5 Πίνακας Συμμεταβλητότητας (Covariance Matrix).....                       | 37 |
| 3.4.6 Ιδιοδιανύσματα και Ιδιοτιμές (Eigenvectors , Eigenvalues).....           | 38 |
| 3.5 Αλγόριθμοι Εξαγωγής Χαρακτηριστικών.....                                   | 39 |
| 3.5.1 Principal Component Analysis.....  | 39 |
| 3.5.2 Feedback Clasification Algorithm.....                                    | 41 |

|   |   |    |
|---|---|----|
| 3.5.3   | Band Ratio.....   | 41 |
| <b>Κεφάλαιο 4° Ταξινόμηση Υπερφασματικών Δεδομένων (Hyperspectral Imaging Classification)</b> |   |    |
| 4.1   | Εισαγωγή.....   | 43 |
| 4.2   | Αναγνώριση Προτύπων (Pattern Recognition).....                      | 43 |
| 4.3   | Υπερφασματική Ταξινόμηση (Hyperspectral Classification).....        | 45 |
| 4.4   | Μέθοδοι ταξινόμησης.....  | 45 |
| 4.5   | Το στάδιο εκπαίδευσης (Training Stage).....                         | 47 |
| 4.6   | Αποτίμηση της ακρίβειας (Accuracy Assessment).....                  | 48 |
| 4.7   | Βιβλιοθήκες Φασμάτων (Spectral Libraries).....                      | 49 |
| 4.8   | Μέθοδοι Συλλογής Φασμάτων Αναφοράς.....                             | 49 |
| 4.9   | Φασματικός Διαχωρισμός (Spectral Unmixing).....                     | 51 |
| <b>Κεφάλαιο 5° Αλγόριθμοι Ταξινόμησης</b>   |   |    |
| 5.1   | Εισαγωγή.....   | 53 |
| 5.2   | Parallelepiped Classification.....                                  | 54 |
| 5.3   | Nearest Neighbour.....  | 55 |
| 5.5   | Euclidean Distance.....   | 56 |
| 5.6   | Maximum Likelihood.....   | 57 |
| 5.6   | Bayes Classifier.....   | 59 |
| 5.7   | Fisher's Linear Discriminant.....                                   | 62 |
| 5.8   | Mahalanobis Distance.....   | 63 |
| 5.9   | Null Class.....   | 63 |
| 5.10  | Isodata Classifier.....   | 64 |
| 5.11  | Spectral Angle Mapper.....  | 66 |
| 5.12  | Ασαφείς Μέθοδοι Ταξινόμησης (Fuzzy Classification) .....            | 67 |
| 5.12.1  | Linear Spectral Unmixing.....                                       | 68 |
| 5.12.2  | Pixel Purity Index.....   | 68 |
| 5.12.3  | Mixed Tuned Matched Filtering.....                                  | 69 |
| 5.12.4  | Spectral Feature Fitting.....                                       | 69 |
| <b>Κεφάλαιο 6° Συμπεράσματα</b>   |   |    |
| 6.1   | Γενικά.....   | 71 |
| 6.2   | Προβλήματα στην ταξινόμηση.....                                     | 71 |
| 6.3   | Παράγοντες που επηρεάζουν την ταξινόμηση.....                       | 72 |
|   | • Training Set.....   | 72 |
|   | • Διαστατικότητα του χώρου χαρακτηριστικών.....                     | 73 |
|   | • Αριθμός των Clusters.....   | 73 |
|   | • Χωρική Ανάλυση.....   | 73 |
| 6.4   | Εναλλακτικές τεχνικές .....   | 73 |
| 6.4.1   | Ανάπτυξη του παραλληλισμού.....                                     | 74 |
| 6.4.2   | Τεχνικές ελεύθερης κατανομής.....                                   | 74 |
| 6.4.3   | Support Vector Machines.....  | 75 |
| 6.4.4   | Θέματα αναπαράστασης.....   | 75 |
| 6.4.5   | Αντικειμενοστρεφής Ταξινόμηση (Object-oriented Classification)..... | 76 |
| <b>Κεφάλαιο 7° Υλοποίηση Αλγορίθμων.....</b>  |   |    |
| <b>77</b>   |   |    |
| <b>Κεφάλαιο 8° Αποτελέσματα</b>   |   |    |
| 8.1   | Ταξινόμηση για 5 τάξεις.....  | 83 |
| 8.2   | Ταξινόμηση για 9 τάξεις.....  | 84 |
| 8.3   | Ταξινόμηση για 12 τάξεις.....                                       | 86 |
| 8.4   | Ταξινόμηση για 20 τάξεις.....                                       | 87 |
| 8.5   | Κάποια συμπεράσματα για την ταξινόμηση.....                         | 89 |
| <b>Βιβλιογραφία.....</b>  |   |    |
| <b>90</b>   |   |    |

## Ευρετήριο εικόνων

Σελίδα

|           |  |    |
|-----------|--|----|
| Εικ . 1   | - Ένα τυπικό σύστημα ταξινόμησης υπερφασματικών δεδομένων.....   | 7  |
| Εικ . 2   | - Σχηματική αναπαράσταση του ηλεκτρομαγνητικού κύματος.....  | 9  |
| Εικ . 3   | - Κλασική και κβαντική θεώρηση του ηλεκτρομαγνητικού κύματος.....  | 10 |
| Εικ . 4   | - Σχηματική απεικόνιση του φαινομένου σκέδασης .....   | 14 |
| Εικ . 5   | - Hyperspectral data cubes του Fort Desoto Park και του Morro Bay.....   | 17 |
| Εικ . 6   | - Αποκατάσταση απανθρακωμένων και συμπιεσμένων αρχαίων πάπυρων.....  | 17 |
| Εικ . 7   | - Φωτοδιεγερμένη βλεννώδης μεμβράνη ιστού.....   | 18 |
| Εικ . 8   | - Hyperspectral data cube ανθρώπινου εγκεφάλου.....  | 19 |
| Εικ . 9   | - Σχηματική περιγραφή της τηλεπισκόπησης.....  | 20 |
| Εικ . 10  | - Τέσσερις όψεις του καρκίνου Nebula.....  | 21 |
| Εικ . 11  | - Ψευδοχρωματική εικόνα , ζώνες 4 (υπερύθρο), 3 (ερυθρό) και 2 (πράσινο).....  | 22 |
| Εικ . 12  | - Υπερφασματικός κύβος του συστήματος AVIRIS.....  | 23 |
| Εικ . 13  | - Οι διαστάσεις ενός υπερφασματικού κύβου.....   | 24 |
| Εικ . 14  | - Οι φασματικές υπογραφές για τέσσερα διαφορετικά υλικά.....   | 26 |
| Εικ . 15  | - Συγκριτική αναπαράσταση των τεχνικών της υπερφασματικής και πολυφασματικής απεικόνισης.....  | 27 |
| Εικ . 16  | - Η λογική της υπερφασματικής απεικόνισης.....   | 27 |
| Εικ . 17  | - Φάσματα ανάκλασης τριών υλικών όπως θα εμφανιζόντουσαν στον πολυφασματικό αισθητήρα του <b>Landsat 7</b> .....                             | 28 |
| Εικ . 18  | - Τα φάσματα για τα ίδια τρία υλικά, μετρημένα απο εργαστηριακό φασματόμετρο.....  | 28 |
| Εικ . 19  | - Τα φάσματα ανάκλασης για τα ίδια τρία υλικά, όπως θα εμφανιζόντουσαν απο τον υπερφασματικό αισθητήρα του <b>AVIRIS</b> .....               | 29 |
| Εικ . 20  | - Εφαρμογές της υπερφασματικής απεικόνισης στη φυτοπαθολογία και τη γεωλογία.....  | 29 |
| Εικ . 21  | - Δισδιάστατη αναπαράσταση διαφόρων υλικών στο χώρο χαρακτηριστικών του κόκκινου και κοντινού υπέρυθρου.....                                 | 34 |
| Εικ . 22  | - Η λογική στην Unsupervised και Supervised ταξινόμηση αντίστοιχα.....   | 46 |
| Εικ . 23  | - 10 x 10 pixel περιοχή μίας υπερφασματικής εικόνας για ανάλυση μεθόδων συλλογής φασμάτων αναφοράς.....                                      | 50 |
| Εικ . 24  | - Οι φασματικές γωνίες μεταξύ των pixels της περιοχής που επιλέξαμε και των φασμάτων αναφοράς.....   | 50 |
| Εικ . 25  | - Σχηματική απεικόνιση για την αύξηση της χωρικής ανάλυσης του αισθητήρα (μείωση μεγέθους pixel) για το φασματικό διαχωρισμό των υλικών..... | 51 |
| Εικ . 26  | - Δύο θεματικοί χάρτες της ίδιας περιοχής , ταξινομημένης με συμβατικούς και υπερφασματικούς αλγόριθμους αντίστοιχα.....                     | 53 |
| Εικ . 27  | - Τα ιστογράμματα δύο τάξεων για μια συγκεκριμένη ζώνη με το σκιαζόμενο κομμάτι να δείχνει τις “close enough” περιοχές των δύο τάξεων.....   | 62 |
| Εικ . 28  | - Η λογική του αλγορίθμου Spectral Angle Mapper.....   | 67 |
| Εικ . 29  | - Εικόνα του προγράμματος <b>ENVI</b> (Environment for Visualizing Images) για την αφαίρεση του continuum του φάσματος.....                  | 70 |
| Εικ . 30  | - Η RGB εικόνα της ταξινόμησης μας.....  | 82 |
| Εικ . A1  | - Αλγόριθμος Nearest Neighbour , 5 τάξεις.....   | 83 |
| Εικ . A2  | - Αλγόριθμος Spectral Angle Mapper , 5 τάξεις.....   | 83 |
| Εικ . A3  | - Αλγόριθμος Euclidean Distance , 5τάξεις.....   | 84 |
| Εικ . A4  | - Αλγόριθμος Nearest Neighbour , 9 τάξεις.....   | 84 |
| Εικ . A5  | - Αλγόριθμος Spectral Angle Mapper , 9 τάξεις.....   | 85 |
| Εικ . A6  | - Αλγόριθμος Euclidean Distance , 9 τάξεις.....  | 85 |
| Εικ . A7  | - Αλγόριθμος Nearest Neighbour , 12 τάξεις.....  | 86 |
| Εικ . A8  | - Αλγόριθμος Spectral Angle Mapper , 12 τάξεις.....  | 86 |
| Εικ . A9  | - Αλγόριθμος Euclidean Distance , 12 τάξεις.....   | 87 |
| Εικ . A10 | - Αλγόριθμος Nearest Neighbour , 20 τάξεις.....  | 87 |

|   |    |
|---|----|
| Εικ . A11 - Αλγόριθμος Spectral Angle Mapper , 20 τάξεις..... | 88 |
| Εικ . A12 - Αλγόριθμος Euclidean Distance , 20 τάξεις.....    | 88 |

## Ευρετήριο πινάκων και διαγραμμάτων

σελίδα

|   |    |
|---|----|
| Πίνακας 1 - Οι κύριες διαιρέσεις του ηλεκτρομαγνητικού φάσματος.....  | 6  |
| Πίνακας 2 - Οι βασικές υποδιαιρέσεις (αποχρώσεις) και η ορατή περιοχή του ηλεκτρομαγνητικού φάσματος.....   | 6  |
| Πίνακας 3 - Σημερινοί και πρόσφατοι υπερφασματικοί αισθητήρες.....  | 19 |
| Πίνακας 4 - Οι προδιαγραφές κάποιων αισθητήρων υπερφασματικής απεικόνισης.....  | 26 |
| Πίνακας 5 - Παράδειγμα ενός πίνακα ακρίβειας.....   | 41 |
| <br>  |    |
| Διαγρ . 1 - Φαινόμενα αλληλεπίδρασης ηλεκτρομαγνητικής ακτινοβολίας και ύλης.....   | 7  |
| Διαγρ . 2 - Ατομικό σύστημα αποτελούμενο απο δύο ενεργειακές στάθμες.....   | 7  |
| Διαγρ . 3 - Διάγραμμα Jablonski.....  | 8  |
| Διαγρ . 4 - Η διεργασία ενίσχυσης του πληθυσμού των φωτονίων μέσω της σκέδασης Raman .....  | 10 |
| Διαγρ . 5 - Τεχνικές φασματικής απεικόνισης.....  | 21 |
| Διαγρ . 6 - Αναπαράσταση των Principal Components.....  | 34 |
| Διαγρ . 7 - Το γενικό διάγραμμα ενός συστήματος Αναγνώρισης Προτύπων.....   | 36 |
| Διαγρ . 8 - Τα όρια απόφασης στο χαρακτηριστικό πεδίο για τρεις τάξεις λουλουδιών.....  | 37 |
| Διαγρ . 9 - Επικάλυψη δύο διαφορετικών τάξεων σε μία περιοχή του χαρακτηριστικού πεδίου.....  | 38 |
| Διαγρ .10- Η λογική των βημάτων στην Supervised και Unsupervised ταξινόμηση.....  | 39 |
| Διαγρ .11- Τα φάσματα αναφοράς που έχουν υπολογιστεί με τις διάφορες μεθόδους συλλογής φασμάτων αναφοράς για 17 κανάλια.....                          | 43 |
| Διαγρ .12- Κατανομή της συχνότητας δεδομένων για μία τάξη $\omega$ , σε μία ζώνη $k$ .....  | 50 |
| Διαγρ .13- Κατανομή της συχνότητας δεδομένων για μία τάξη $\omega$ , σε μία ζώνη $k$ , στρογγυλοποιημένη απο τη συνάρτηση πυκνότητας πιθανότητας..... | 50 |
| Διαγρ .14- Ο συνδυασμός και των δύο συναρτήσεων απόφασης , Nearest Neighbour και Bayes Classifier.....  | 54 |
| Διαγρ .15- Τα βήματα στη βασική ρουτίνα εκτέλεσης των Supervised αλγορίθμων Nearest Neighbour και Spectral Angle Mapper.....                          | 69 |
| Διαγρ .16- Τα βήματα εκτέλεσης του επαναληπτικού Unsupervised αλγορίθμου Euclidean Distance.....  | 70 |
| Διαγρ .17- Η αλλαγή του μέσου σε μία επανάληψη του αλγορίθμου.....  | 71 |

## ΕΙΣΑΓΩΓΗ

Τα τελευταία χρόνια έχει παρατηρηθεί ένα συνεχώς αυξανόμενο ενδιαφέρον για την υπερφασματική απεικόνιση, με πλήθος εφαρμογών σε διάφορα επιστημονικά πεδία όπως μεταξύ άλλων η ιατρική, η βιομηχανία, η αναλυτική χημεία, η βιοχημεία και το περιβάλλον.

Μέχρι τις αρχές της προηγούμενης δεκαετίας μόνο ειδικοί στον τομέα της φασματικής τηλεπισκόπησης είχαν πρόσβαση σε υπερφασματικές εικόνες και σε λογισμικά για την εκμετάλλευσή τους.

Σήμερα η ανάλυση υπερφασματικής απεικόνισης έχει εξελιχθεί σε ένα απ'τα πιο ισχυρά και ταχέως αναπτυσσόμενα εργαλεία στον τομέα της τηλεπισκόπησης.


Το «υπέρ» στο υπερφασματική αναφέρεται στον τεράστιο αριθμό των μετρομένων ζωνών μήκους κύματος .

Τα υπερφασματικά δεδομένα αποτελούνται απο ένα μεγάλο αριθμό φασματικών ζωνών με σχετικά μικρό εύρος φάσματος.

Για παράδειγμα ο αισθητήρας του Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) συλλέγει δεδομένα σε 224 φασματικές ζώνες με εύρος φάσματος απο 0.4 ως 2.5 μm φασματική ανάλυση, και 20 m χωρική .

Οι υπερφασματικές εικόνες μας παρέχουν ευρεία φασματική πληροφορία για την αναγνώριση και το διαχωρισμό υλικών ,παρέχοντάς μας έτσι μια προοπτική για πιο ακριβή και λεπτομερή εξαγωγή πληροφορίας απο οποιοδήποτε άλλο τύπο τηλεσκοπικών δεδομένων .

Η ταξινόμηση μιας υπερφασματικής εικόνας είναι η διαδικασία της δημιουργίας μιας πληροφοριακής αναπαράστασης της εικόνας, η οποία θα μας δείξει τη χωρική κατανομή κάποιων χαρακτηριστικών διαγνωστικής σημασίας σε μια περιοχή που μας ενδιαφέρει.



*Εικ . 1 Ένα τυπικό σύστημα ταξινόμησης υπερφασματικών δεδομένων*

Η εικόνα 1 μας δείχνει την οργάνωση ενός συστήματος υπερφασματικής απεικόνισης .

Όπως παρατηρούμε το σύστημα μπορεί να διαιρεθεί σε τρία βασικά κομμάτια : την προεπεξεργασία των δεδομένων (pre-processing) , την εξαγωγή των χαρακτηριστικών (feature extraction) και τέλος την ταξινόμηση (classification).

Η προεπεξεργασία γενικά προηγείται της ανάλυσης των δεδομένων ή της εξαγωγής της πληροφορίας και σκοπός της είναι η μείωση του θορύβου ή ο εμπλουτισμός κάποιας όψης των δεδομένων . Υπάρχει μεγάλος αριθμός τύπων προεπεξεργασίας που εφαρμόζονται στα δεδομένα.

Κάποια παραδείγματα είναι : Ραδιομετρική βαθμονόμηση (Radiometric Calibration), Ατμοσφαιρική Διόρθωση (Atmospheric Correction), Εμπλουτισμός του Contrast και Image Registration .

Η εξαγωγή των χαρακτηριστικών είναι ένα προαιρετικό βήμα της διαδικασίας ταξινόμησης και εξυπηρετεί σαν προεπεξεργασία της εικόνας στη μείωση της φασματικής ή χωρικής διαστατικότητας της εικόνας.

Επιτυγχάνεται επιλέγοντας ένα βέλτιστο υποσύνολο των καναλιών (ζωνών) με σκοπό να αποφευχθούν προβλήματα εκτίμησης τα οποία οφείλονται στον υψηλό συσχετισμό μεταξύ κάποιων ζωνών.

Σε αυτό το στάδιο η υπερφασματική εικόνα έχει μετασχηματιστεί σε μία εικόνα χαρακτηριστικών .Οι αλγόριθμοι εξαγωγής χαρακτηριστικών πρέπει να είναι σχεδιασμένοι να διατηρούν την πληροφορία που μας ενδιαφέρει για ένα συγκεκριμένο πρόβλημα όπως είναι η ταξινόμηση.

Η ταξινόμηση των υπερφασματικών δεδομένων είναι η διαδικασία ταυτοποίησης και καταχώρησης του κάθε pixel της εικόνας σε μία συγκεκριμένη τάξη σύμφωνα με κάποια στατιστικά χαρακτηριστικά των τιμών των εντάσεων του κάθε pixel .

Υπάρχουν δύο γενικές προσεγγίσεις οι οποίες χρησιμοποιούνται στη διαδικασία της ταξινόμησης , η **Supervised** και η **Unsupervised** ταξινόμηση.

Τα ταξινομημένα αποτελέσματα πρέπει να ελέγχονται και να πιστοποιείται η ακρίβεια και η αξιοπιστία τους .

Στα κεφάλαια που ακολουθούν θα περιγράψουμε αναλυτικά τη συνολική διαδικασία της ταξινόμησης υπερφασματικών δεδομένων και θα εξετάσουμε σε βάθος κάποιους απ'τους αλγόριθμους που χρησιμοποιούνται σε αυτή.



# Κεφάλαιο 1<sup>ο</sup>

## Εισαγωγή στη φασματοσκοπία

### 1.1 Εισαγωγή


Για να μπορέσουμε να κατανοήσουμε σε βάθος τα πλεονεκτήματα της υπερφασματικής απεικόνισης κρίνεται σκόπιμη μία σύντομη ανασκόπηση σε βασικά θέματα φασματοσκοπίας, ξεκινώντας απ'την αλληλεπίδραση μεταξύ ηλεκτρομαγνητικής ακτινοβολίας και ύλης .

### 1.2 Η ηλεκτρομαγνητική ακτινοβολία

Η ηλεκτρομαγνητική ακτινοβολία είναι ένα εγκάρσιο ενεργειακό κύμα το οποίο συνίσταται από ένα ταλαντώμενο ηλεκτρικό πεδίο  $E$ , και ένα ταλαντώμενο μαγνητικό πεδίο  $M$ .

Το ηλεκτρικό και μαγνητικό πεδίο είναι ορθογώνια μεταξύ τους, όπως και στην διεύθυνση διάδοσης του κύματος.

Το κύμα περιγράφεται από ένα μήκος κύματος  $\lambda$ , που αντιστοιχεί στο φυσικό μήκος μιας πλήρους ταλάντωσης, και μία συχνότητα  $\nu$ , που αντιστοιχεί στον αριθμό των ταλαντώσεων ανά δευτερόλεπτο.



*Εικ . 2 Το ηλεκτρομαγνητικό κύμα περνάει μέσα από το κενό με την ταχύτητα του φωτός  $c = 2.99792 \times 10^8 \text{ m/s}$ . Η σχέση που συνδέει τα  $c$ ,  $\lambda$ , και  $\nu$  είναι η  $c = \lambda \nu$*


Η ηλεκτρομαγνητική ακτινοβολία παρουσιάζει και κυματικά και σωματιδιακά χαρακτηριστικά.

Αυτή τη **δυική φύση της ακτινοβολίας**, την σωματιδιακή και κυματική, οι οποίες δεν αποκλείουν η μία την άλλη αλλά αλληλοσυμπληρώνονται, αντιλήφθηκε πρώτος ο **Einstein** και την εξέφρασε σαν μία συνεχή ροή διακριτών σωματιδίων ή κυματικών ενεργειακών «πακέτων» τα οποία αργότερα ονομάστηκαν **φωτόνια** .

Η ενέργεια  $E$  ενός φωτονίου εξαρτάται από τη συχνότητα (ή το μήκος κύματος) της ακτινοβολίας

$$E = h \nu = hc / \lambda$$

όπου  $h$  είναι η σταθερά Planck ( $6.62618 \times 10^{-34}$  Js),  $c$  η ταχύτητα του φωτός,  $\nu$  η συχνότητα και  $\lambda$  το μήκος κύματος της ακτινοβολίας.



**Εικ . 3** Κινούμενα σωματίδια όπως τα ηλεκτρόνια, πρωτόνια και νετρόνια παρουσιάζουν επίσης κυματικά χαρακτηριστικά όπως αυτά περιγράφονται από την εξίσωση **de Broglie**  
 $\lambda = h / p$  ( $p$  η ορμή του σωματιδίου)

### 1.3 Το ηλεκτρομαγνητικό φάσμα

Ολόκληρο το εύρος του μήκους κύματος της ηλεκτρομαγνητικής ακτινοβολίας αποτελεί το ηλεκτρομαγνητικό φάσμα.

Για λόγους ευκολίας διαιρούμε το ηλεκτρομαγνητικό φάσμα σε φασματικές περιοχές οι οποίες λόγω των διαφορετικών ενεργειών αλληλεπιδρούν με την ύλη πολύ διαφορετικά.

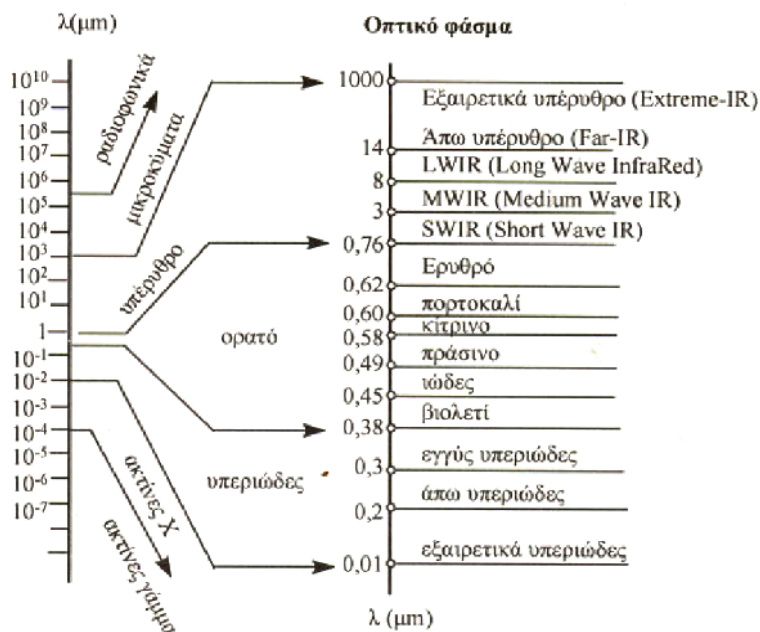
Μια φασματική ζώνη (**spectral band**) αποτελείται από κάποια καθορισμένη ομάδα φασματικών γραμμών, όπου κάθε φασματική γραμμή αντιστοιχεί σε συγκεκριμένο μήκος κύματος.

Οι φασματικές ζώνες του ηλεκτρομαγνητικού φάσματος μπορούν επιγραμματικά να χωριστούν στις ακόλουθες ομάδες σύμφωνα με το μήκος κύματος :

| Φασματική Ζώνη        | Μήκος Κύματος ( $\lambda$ )             |
|-----------------------|---|
| Ακτίνες γάμμα         | < 0,03 nm                               |
| Ακτίνες X             | 0,03 nm – 300 nm                        |
| Υπεριώδης ακτινοβολία | 0,30 $\mu\text{m}$ – 0,38 $\mu\text{m}$ |
| Ορατό                 | 0,38 $\mu\text{m}$ – 0,72 $\mu\text{m}$ |
| Εγγύς Υπέρυθρο        | 0,72 $\mu\text{m}$ – 1,30 $\mu\text{m}$ |
| Μέσο Υπέρυθρο         | 1,30 $\mu\text{m}$ – 3 $\mu\text{m}$    |
| Άπω Υπέρυθρο          | 7,00 $\mu\text{m}$ – 15 $\mu\text{m}$   |
| Μικροκύματα           | 0,3 cm – 30 cm                          |
| Ραδιοφωνικά κύματα    | $\geq 30$ cm                            |

**Πίνακας 1** Για τον ήλιο το φάσμα εκτείνεται από τις ακτίνες γάμμα (μικρό μήκος κύματος και υψηλή ενέργεια) μέχρι τα ραδιοκύματα (μεγάλο μήκος κύματος και χαμηλή ενέργεια).

Οι κύριες διαιρέσεις του ηλεκτρομαγνητικού φάσματος ορίζονται στην ουσία αυθαίρετα, αφού μεταξύ συγκεκριμένων ζωνών του φάσματος υπάρχουν πολλές υποδιαιρέσεις (αποχρώσεις), επειδή η μετάβαση από τη μία ζώνη φάσματος στην άλλη είναι βαθμιαία και όχι απότομη.



**Πίνακας 2** Οι βασικές υποδιαιρέσεις (αποχρώσεις) και η ορατή περιοχή του ηλεκτρομαγνητικού φάσματος


## 1.4 Αλληλεπίδραση ακτινοβολίας και ύλης - Φασματοσκοπία

Η φασματοσκοπία θα μπορούσε να οριστεί ως η χρήση των φαινομένων αλληλεπίδρασης της ηλεκτρομαγνητικής ακτινοβολίας με την ύλη :

**απορρόφηση**(absorption), **εκπομπή**(emission), **σκέδαση** (scattering) με σκοπό την ποσοτική ή ποιοτική ανάλυση της ύλης ή τη μελέτη φυσικών διεργασιών.

Η ύλη μπορεί να είναι άτομα, μόρια, ατομικά ή μοριακά ιόντα ή στερεά.


Η αλληλεπίδραση της ακτινοβολίας με την ύλη μπορεί να προκαλέσει ανακατεύθυνση της ακτινοβολίας και/ή μεταπτώσεις ανάμεσα στα ενεργειακά επίπεδα των ατόμων ή μορίων.



*Διαγρ. 1* Οποιαδήποτε δέσμη φωτονίων απο μία πηγή περάσει απο κάποιο μέσο (συνήθως αέρα) και έρθει σε επαφή με κάποιο αντικείμενο θα συμβεί ένα απο τα φαινόμενα του διαγράμματος .

### 1.4.1 Απορρόφηση-Εκπομπή

Η φυσική βάση της φασματοσκοπίας είναι η αλληλεπίδραση φωτός και ύλης πράγμα το οποίο εντοπίστηκε από τον **Hertz** κατά τη διάρκεια πειραμάτων ανακαλύπτοντας τυχαία το φωτοηλεκτρικό φαινόμενο.



*Διαγρ. 2* Ατομικό σύστημα αποτελούμενο απο δύο ενεργειακές στάθμες

Θεωρούμε ατομικό σύστημα αποτελούμενο από δύο ενεργειακές στάθμες  $E_0$  και  $E_1$  με  $E_0 < E_1$  οι οποίες καταλαμβάνονται από ηλεκτρόνια. Έστω ότι το άτομο βρίσκεται στην κατάσταση  $n=0$ , με ενέργεια  $E_0$ .

Τα ηλεκτρόνια του ατόμου αυτού μπορούν να μεταβούν σε μία διεγερμένη κατάσταση  $n=1$  υψηλότερης ενέργειας  $E_1$ , αν αλληλεπιδράσει με αυτό θερμική ακτινοβολία πυκνότητας ενέργειας  $J$  (βλ. N. Planck) και συχνότητας  $\omega$  τέτοιας ώστε το γινόμενο  $h\omega$  να ισούται με τη διαφορά ενέργειας των δύο επιπέδων, δηλαδή  $h\omega = E_1 - E_0$ .


Το παραπάνω φαινόμενο ονομάζεται **απορρόφηση** (absorption). Η μετάπτωση από τη διεγερμένη κατάσταση  $n=1$  στην αρχική κατάσταση  $n=0$ , με την ταυτόχρονη εκπομπή ενός φωτονίου με συχνότητα  $\omega$ , όπου  $h\omega = E_1 - E_0$ , ονομάζεται **εκπομπή** (emission).

### 1.4.2 Φθορισμός-Φωσφορισμός

Όταν ένα εξωτερικό ηλεκτρόνιο διεγείρεται σε ένα υψηλότερο ενεργειακά επίπεδο με απορρόφηση ακτινοβολίας τότε αυτό μπορεί να επιστρέψει στην βασική στοιβάδα με ή χωρίς εκπομπή ακτινοβολίας.

Στην περίπτωση της εκπομπής έχουμε δύο διαφορετικές διεργασίες με διαφορετικά χαρακτηριστικά: τον **φθορισμό** (fluorescence) και τον **φωσφορισμό** (phosphorescence). Και τα δύο φαινόμενα ονομάζονται συνολικά **φωταύγεια** (luminescence).

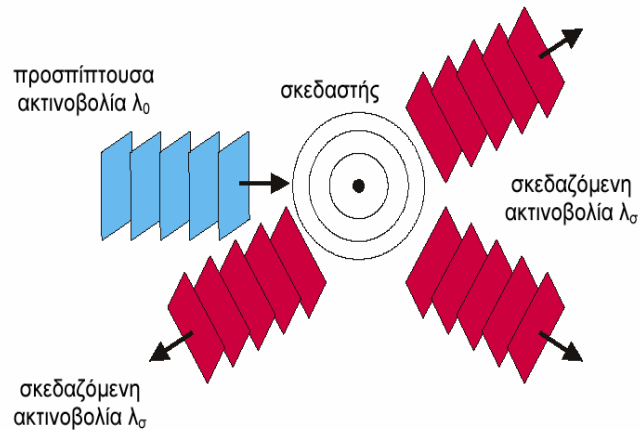
Η βασική διαφορά μεταξύ φθορισμού και φωσφορισμού είναι ο χρόνος που διαρκεί η ακτινοβολία μετά την διέγερση.



*Διαγρ. 3 Η ερμηνεία των δυο φαινομένων δίνεται σχηματικά με το γνωστό ως διάγραμμα **Jablonski**, όπου με παράλληλες γραμμές συμβολίζονται η βασική και οι διάφορες διεγερμένες ενεργειακές στάθμες.*

### 1.4.3 Σκέδαση

Η απορρόφηση ενέργειας από ένα σύστημα (σκεδαστής) από ένα προσπίπτον φωτόνιο και η επανεκπομπή μέρους της ενέργειας του παραπάνω φωτονίου από το ίδιο σύστημα ορίζεται σαν σκέδαση .



*Εικ . 4 Η σκεδαζόμενη ακτινοβολία μπορεί να έχει διαφορετικό μήκος κύματος  $\lambda_{\sigma}$ , ένταση, φάση, διεύθυνση διάδοσης και πόλωση από την προσπίπτουσα ακτινοβολία.*

Το φαινόμενο της σκέδασης εξαρτάται από την φύση του σκεδαστή (υλικό, μέγεθος) και την διάταξη του στο χώρο (τυχαία ή κατανεμημένη).

#### 1.4.3.1 Είδη Σκέδασης

- **Σκέδαση Rayleigh**

Η σκέδαση φωτός Rayleigh παρατηρείται για σκεδαστές με μέγεθος μικρότερο του μήκους κύματος  $\lambda_0$  της προσπίπτουσας ακτινοβολίας .Το εκπεμπόμενο φωτόνιο μπορεί να έχει την ίδια ή μικρότερη ενέργεια σε σχέση με το προσπίπτον φωτόνιο .

Η ένταση  $I_R$  της Rayleigh-σκεδαζόμενης ακτινοβολίας είναι αντιστρόφως ανάλογη με την τέταρτη δύναμη του μήκους κύματος της ακτινοβολίας :

$$I_R \propto \frac{1}{\lambda_0^4}$$


#### **Παραδείγματα φαινομένων σχετιζόμενων με τη σκέδαση Rayleigh:**

- Κυανό χρώμα ουρανού,αλλαγή χρωματισμού ουρανού κατά τη δύση και ανατολή του ηλίου.
- Απώλειες ενέργειας κατά τη διάδοση ακτινοβολίας σε διάφανα στερεά (οπτικά στοιχεία,κρυστάλλους,οπτικές ίνες).

- **Σκέδαση Raman**

Η σκέδαση Raman παρατηρείται κατά την ταυτόχρονη διέλευση δύο φωτονίων συχνοτήτων  $\omega_0$  και  $\omega_s$  ( $\omega_s < \omega_0$ ) από το οπτικό μέσο, όπου το φωτόνιο  $\omega_0$  απορροφάται και ένα μέρος του επανεκπέμπεται με την συχνότητα  $\omega_s$ , του αρχικού συνοδεύοντος φωτονίου.

Η ενέργεια  $h(\omega_0 - \omega_s)$  εκπέμπεται ως **φωνόνιο** (phonon). Η σκέδαση Raman ουσιαστικά αποτελεί διεργασία ενίσχυσης του πληθυσμού φωτονίων  $\omega_s$ , μέσω των φωτονίων  $\omega_0$ .



*Διαγρ . 4 Η διεργασία ενίσχυσης του πληθυσμού των φωτονίων*

Η σκέδαση Raman παρατηρείται σε στερεά, υγρά και αέρια μέσα διάδοσης και λαμβάνει χώρα κατά την χρήση υψηλών εντάσεων ακτινοβολίας .

Τα προσπίπτοντα και σκεδαζόμενα φωτόνια βρίσκονται σε συμφωνία φάσης .

**Άλλα είδη σκέδασης :**

- **Σκέδαση Mie**

- Ισχυρή σκέδαση από σωματίδια με διαστάσεις μεγαλύτερες του  $\lambda_0$
- Ισχυρή εξάρτηση εντάσεως σκέδασης από τη γωνία παρατήρησης
- Το σκεδαζόμενο φως έχει χαρακτηριστική κατάσταση πόλωσης
- Η ένταση της σκέδασης IM ισούται με την σκέδαση που προκύπτει από μοναδιαίο σκεδαστή επί το πλήθος των σκεδαστών

- **Σκέδαση Stokes και Anti-Stokes**

Παρατηρείται κατά την απορρόφηση ενός φωτονίου  $\omega_0$  από ένα μόριο, και την ακόλουθη διέγερση του μορίου σε ένα δονητικό επίπεδο  $v=1$ , με την ταυτόχρονη εκπομπή ενός φωτονίου  $\omega_s$ , όπου  $\omega_s = \omega_0 - \omega_v$  ενώ στην **Anti-Stokes** έχουμε την αποδιέγερση ενός δονητικού επιπέδου ενός μορίου από μια κατάσταση  $v=1$ , σε μία άλλη χαμηλότερη  $v=0$ , με την ταυτόχρονη απορρόφηση ενός φωτονίου  $\omega_s$ , η οποία οδηγεί στην εκπομπή ενός φωτονίου  $\omega_0 = \omega_s + \omega_v$ .

- **Σκέδαση Brillouin**

Παρατηρείται κατά την διάδοση ενός φωτονίου  $\omega_0$  σε κρυσταλλικά μέσα, όπου το αρχικό φωτόνιο απορροφάται από το κρυσταλλικό πλέγμα και επανεκπέμπεται σαν συνδυασμός ενός φωτονίου χαμηλότερης συχνότητας  $\omega_s$  και ενός φωνονίου  $\omega_f$ , όπου  $\omega_0 = \omega_s + \omega_f$ .

## 1.5 Είδη Φασματοσκοπίας

Τα είδη της φασματοσκοπίας βασίζονται κυρίως στα παραπάνω φαινόμενα αλληλεπίδρασης του φωτός με την ύλη, έτσι μπορούμε να διακρίνουμε τη φασματοσκοπία απορρόφησης, τη φασματοσκοπία εκπομπής, ανάκλασης φθορισμού και σκέδασης (IR Raman Spectroscopy) με κάθε είδος να εξυπηρετεί περισσότερο ή λιγότερο συγκεκριμένες ανάγκες.

Στη διαγνωστική ιατρική για παράδειγμα ενώ η **Raman** φασματοσκοπία μας παρέχει περισσότερη πληροφορία για ένα δείγμα από τη **φασματοσκοπία φθορισμού**, η φασματοσκοπία φθορισμού είναι αυτή που προτιμάται αφού τα σήματά της είναι μικρότερα και δυνατότερα αλλά είναι και εφικτή με φτηνότερη εγκατάσταση οργάνων.

Σε άλλες ιατρικές εφαρμογές όμως στις οποίες απαιτείται περισσότερη πληροφορία χρησιμοποιείται Raman φασματοσκοπία.

Η **φασματοσκοπία εκπομπής** (emission spectroscopy) διαφέρει από τους υπόλοιπους τύπους διότι δεν απαιτούνται εξωγενείς πηγές ακτινοβολίας. Το ίδιο το δείγμα είναι ο εκπομπός.

## 1.6 Ενδεικτικές εφαρμογές φασματοσκοπίας

Η φασματοσκοπία είναι πλέον ένα ευρέως διαδεδομένο εργαλείο το οποίο χρησιμοποιείται εδώ και δεκαετίες σε πλήθος εφαρμογών σε διάφορους τομείς.

- **Αναλυτική χημεία** : η φασματοσκοπία χρησιμοποιείται κατά κόρον στην αναλυτική χημεία και κυρίως στη στοιχειομετρία διαλυμάτων .

Για κάθε ουσία υπάρχει μια πρότυπη καμπύλη συγκέντρωσης-απορρόφησης (A ) ή συγκέντρωσης -διαπερατότητας (%T ), η οποία συγκρίνεται με την αντίστοιχη καμπύλη που εξάγεται από τον στοιχειομετρικό αναλυτή και έτσι καθορίζεται η ποσοτική και ποιοτική ανάλυση του διαλύματος .

- **Βιοχημεία** : σημαντικό ρόλο διαδραματίζει η φασματοσκοπία και στην περιοχή της βιοχημείας, όπου αναλύει ποσοτικά και ποιοτικά διαλύματα πρωτεϊνών .


- **Διαγνωστικά όργανα** : η φασματοσκοπία είναι από τις πιο βασικές μεθόδους στην **in vitro** ανάλυση, αφού τα περισσότερα διαγνωστικά όργανα την έχουν ως κύρια αρχή λειτουργίας.

Χαρακτηριστικό παράδειγμα είναι οι αναλυτές αίματος, οι οποίοι μέσω μια ειδικής διάταξης και με την βοήθεια της φασματοσκοπίας έχουν την δυνατότητα να μετρούν ποσοτικά και ποιοτικά τα κύτταρα στα δείγματα αίματος .

- **Περιβάλλον** : μια από τις πιο χαρακτηριστικές εφαρμογές της φασματοσκοπίας είναι η μέτρηση ρύπων τόσο στη ατμόσφαιρα όσο και στο υδάτινο περιβάλλον αλλά και η χαρτογράφηση περιοχών μέσω της **τηλεπισκόπησης**, κάτι πολύ χρήσιμο στην **ορυκτολογία** και τη **γεωλογία**.

- **Βιομηχανικές εφαρμογές** : χρησιμοποιείται κυρίως στην ποιοτική ανάλυση των παραγόμενων προϊόντων , το γνωστό και ως **on-line control**.





*Εικ . 5 Hyperspectral data cubes του Fort Desoto Park (αριστερά) και του Morro Bay (δεξιά) .*



*Εικ . 6 Αποκατάσταση αρχαίων πάπυρων οι οποίοι είχαν απανθρακωθεί και συμπιεστεί σε συμπαγή μάζα*

## 1.7 Η φασματοκοπία στην ιατρική

Μία από τις πιο πρωτοποριακές χρήσεις της φασματοσκοπίας στην ιατρική είναι κυρίως η εφαρμογή της σε διαγνωστικές αλλά και θεραπευτικές μεθόδους. Το γεγονός αυτό οφείλεται στα πλεονεκτήματα που έχει η φασματοσκοπία ως **μη επεμβατική** μέθοδος, χαρακτηριστικό ιδιαίτερα σημαντικό όταν αναφερόμαστε σε ζωντανούς οργανισμούς (**in vivo**). Έτσι ένας ιστός μπορεί να μελετηθεί χωρίς να είναι απαραίτητη η αφαίρεση του για ανάλυση.

Αυτή η μέθοδος βιοψίας ονομάζεται **οπτική βιοψία**.

### 1.7.1 Οπτική βιοψία


Η αξία της οπτικής βιοψίας είναι εξαιρετικά μεγάλη. Τα περισσότερα είδη καρκίνου εμφανίζονται αρχικά στη βλεννώδη μεμβράνη και την επιφάνεια των ιστών πριν εισβάλλουν βαθύτερα.

Η ανάλυση των οπτικών χαρακτηριστικών της επιφάνειας των ιστών από τα φασματικά χαρακτηριστικά του ανακλώμενου φωτός προσφέρει τη ρεαλιστική προοπτική της παροχής άμεσης διάγνωσης δυσπλασίας ή πρώιμου καρκίνου.

Αυτό είναι συχνά ανέφικτο μιας και οι αλλαγές αυτές στους ιστούς είναι αόρατες με τις συμβατικές διαγνωστικές μεθόδους κάτι που καθιστά την οπτική βιοψία πολύ σημαντική ιδιαίτερα αν σκεφτούμε ότι τα περισσότερα είδη καρκίνου αντιμετωπίζονται καλύτερα αν διαγνωστούν εγκαίρως.


Για παράδειγμα όταν υγιείς ανθρώπινοι ιστοί εκτεθούν σε ιώδη ακτινοβολία, μέσω του φαινομένου φθορισμού φαίνονται πράσινοι, ενώ οι καρκινογόνοι ιστοί με μία ελαφριά πράσινη απόχρωση. Επιπλέον σε ασθενείς για τους οποίους υπάρχει η υποψία ύπαρξης καρκίνου δίνεται ένα φάρμακο το οποίο αναγκάζει τους προσβεβλημένους ιστούς να φαίνονται κόκκινοι.

Με αυτές τις ιδιότητες μπορούμε να διαγνώσουμε την ύπαρξη καρκίνου σε ανθρώπινους ιστούς εξετάζοντας το φάσμα φθορισμού.



Εικ. 7 Φωτοδιεγερμένη βλεννώδης μεμβράνη ιστού

Μία εξίσου ενδιαφέρουσα εφαρμογή είναι η χρήση της υπερφασματικής απεικόνισης για την χαρτογράφηση περιοχών του εγκεφάλου που εκτελούν συγκεκριμένες λειτουργίες.



*Εικ . 8 Hyperspectral data cube ανθρώπινου εγκεφάλου.*

## 1.8 Τηλεπισκόπηση (Remote Sensing)


Η **τηλεπισκόπηση** είναι η επιστήμη κατά την οποία συγκεντρώνουμε πληροφορίες για τη γήινη επιφάνεια χωρίς να είμαστε σε επαφή με αυτήν πραγματικά.

Αυτό γίνεται με την κατανόηση και την καταγραφή της ανακλώμενης ή εκπεμπόμενης ακτινοβολίας και της επεξεργασίας, ανάλυσης και εφαρμογής αυτής της πληροφορίας. Σε ένα μεγάλο μέρος της τηλεπισκόπησης, η διαδικασία περιλαμβάνει την αλληλεπίδραση μεταξύ της προσπίπτουσας ακτινοβολίας και των υπό εξέταση στόχων.

Τα συστήματα απεικόνισης περιλαμβάνουν συνήθως τα ακόλουθα στοιχεία :

- **Πηγή ενέργειας ή φωτισμός (A)** : Μία πηγή ενέργειας που φωτίζει ή παρέχει την ηλεκτρομαγνητική ενέργεια στο στόχο .
- **Αλληλεπίδραση με την ατμόσφαιρα (B)** : Όπως η ενέργεια ταξιδεύει από την πηγή στο στόχο θα έρθει σε επαφή και θα αλληλεπιδράσει με την ατμόσφαιρα .
- **Αλληλεπίδραση με το στόχο (C)** : Αλληλεπίδραση με το στόχο ανάλογα με τις ιδιότητες του στόχου και της ακτινοβολίας .
- **Καταγραφή της ενέργειας από τον αισθητήρα (D)** : Μετά τη σκέδαση ή εκπομπή της ακτινοβολίας απ' το στόχο χρειαζόμαστε έναν αισθητήρα (μακρινό) για να συλλέξουμε και να καταγράψουμε την ηλεκτρομαγνητική ακτινοβολία .
- **Μετάδοση ,υποδοχή και επεξεργασία (E)** : Η ενέργεια που καταγράφεται από τον αισθητήρα πρέπει να διαβιβαστεί, σε ηλεκτρονική μορφή, σε ένα σταθμό λήψης και επεξεργασίας, όπου τα στοιχεία υποβάλλονται σε επεξεργασία σε μια εικόνα .
- **Ερμηνεία και ανάλυση (F)** : Η επεξεργασμένη εικόνα ερμηνεύεται, οπτικά και /ή ψηφιακά ή ηλεκτρονικά, για να εξαγάγει τις πληροφορίες για το στόχο .

- **Εφαρμογή (G)** : Το τελικό στοιχείο της διαδικασίας τηλεπισκόπησης στο οποίο πια εφαρμόζουμε τις πληροφορίες που έχουμε εξαγάγει από την εικόνα.



Εικ . 9 Σχηματική περιγραφή της τηλεπισκόπησης

### 1.8.1 Τρόποι τηλεπισκόπησης

Προκειμένου ένας αισθητήρας να συλλέγει και να καταγράφει την ενέργεια που ανακλάται ή που εκπέμπεται από έναν στόχο ή μια επιφάνεια, πρέπει να εδράζεται σε μια σταθερή πλατφόρμα.

Οι πλατφόρμες για τους μακρινούς αισθητήρες μπορούν να τοποθετηθούν στο έδαφος, σε αεροσκάφη ή κάποια άλλη πλατφόρμα μέσα στη γήινη ατμόσφαιρα, ή σε ένα διαστημικό σκάφος ή δορυφόρο έξω από τη γήινη ατμόσφαιρα . Λόγω της τροχιάς τους, οι δορυφόροι επιτρέπουν την συνεχή κάλυψη της γήινης επιφάνειας .

Το κόστος είναι συχνά ένας σημαντικός παράγοντας στην επιλογή μεταξύ των διαφόρων επιλογών πλατφορμών .

Οι τρόποι τηλεπισκόπησης συνοψίζονται παρακάτω :

- **Αεροφωτογραφία**
- **Μεμονωμένοι αισθητήρες**
  1. *Differential Optical Absorption Spectroscopy*
  2. *Θερμοκάμερες*
- **Δορυφόροι**

Τα όργανα μέτρησης της Η /Μ ακτινοβολίας ονομάζονται γενικά **ραδιόμετρα** και οι βασικές τους κατηγορίες είναι :

- **Αισθητήρες εικόνας (imagers)**
- **Αισθητήρες μέτρησης**

## 1.9 Πολυφασματικές εικόνες


Μία σημαντική πρόοδος στην τηλεπισκόπηση και την τεχνολογία αισθητήρων προέκυψε από την υποδιαίρεση του εύρους φάσματος της ακτινοβολίας σε ζώνες (**bands**), συνεχούς ή μη μήκους κύματος, επιτρέποντας έτσι στους αισθητήρες να παράγουν, σε διάφορες ζώνες, πολυφασματικές (**multispectral**) εικόνες.

Μία πολυφασματική εικόνα είναι στην ουσία μία συλλογή διαφόρων μονοχρωματικών εικόνων του ίδιου αντικειμένου, η κάθε μία εκ των οποίων έχει ληφθεί με διαφορετικό αισθητήρα. Μία πολύ γνωστή πολυφασματική εικόνα είναι η **RGB** εικόνα η οποία αποτελείται από μία κόκκινη, μία πράσινη και μία μπλέ εικόνα που έχουν ληφθεί με διαφορετικούς αισθητήρες, ο καθένας ευαίσθητος στα συγκεκριμένα μήκη κύματος.

Συνήθως οι δορυφόροι έχουν 3 ως 7 (ή και περισσότερα) ραδιόμετρα (ο **France's SPOT** έχει 3, ο **Landsat** έχει 7) και λαμβάνουν εικόνες σε διάφορες ζώνες συχνοτήτων από την περιοχή του ορατού ως του άπω υπέρυθρου. Ο **Landsat 5** για παράδειγμα, παράγει εικόνες 7 ζωνών με το μήκος κύματος των ζωνών να είναι μεταξύ 450 και 1250 nm .

Η τηλεπισκόπηση στη γη έχει παραδοσιακά χρησιμοποιήσει ανάκλαση στο πεδίο του ορατού και υπέρυθρου και εκπομπή στην περιοχή του θερμικού υπέρυθρου και των μικροκυμάτων για τη δημιουργία πολυφασματικών εικόνων.

Η χρήση των πολυφασματικών εικόνων είναι πολύ συχνή στις απεικονίσεις αστρικών σωμάτων με όργανα τα οποία είναι εξοπλισμένα με διαφορετικούς πολυφασματικούς αισθητήρες .



**Εικ . 10** Τέσσερις όψεις του καρκίνου Nebula ο οποίος βρίσκεται σε κατάσταση χαοτικής επέκτασης μετά από μία *supernova* έκρηξη η οποία έγινε αντιληπτή από κινέζους αστρονόμους το 1054 μ.Χ .

*Η 1η εικόνα δείχνει τον Nebula στο υψηλό ενεργειακό πεδίο των ακτίνων χ, η 2η στο πεδίο του ορατού, η 3η στο πεδίο του υπέρυθρου και η 4η είναι μία μεγάλου μήκους κύματος (ραδιο) τηλεσκοπική εικόνα.*

### Landsat data



*Κοντινό Υπέρυθρο*

*Ερυθρό*

*Συνδυασμός (432)*

**Εικ . 11** *Ψευδοχρωματική εικόνα, ζώνες 4 (υπέρυθρο), 3 (ερυθρό) και 2 (πράσινο).*

# Κεφάλαιο 2<sup>ο</sup>

## Υπερφασματική απεικόνιση (Hyperspectral Imaging)

### 2.1 Εισαγωγή


Η σημαντικότερη και επαναστατικότερη πρόοδος στον τομέα της τηλεπισκόπησης εμφανίστηκε με την ανάπτυξη υπερφασματικών αισθητήρων (**hyperspectral sensors**) και λογισμικού για την ανάλυση των υπερφασματικών δεδομένων.

Η υπερφασματική απεικόνιση είναι μία σχετικά νέα τεχνολογία η οποία αρχικά αναπτύχθηκε με σκοπό την ανίχνευση και ταυτοποίηση κυρίως ορυκτών , βλάστησης και ωκεάνιου φυσικού περιβάλλοντος .

Η φασματοσκοπία μπορεί να χρησιμοποιηθεί για την ανάδειξη ιδιαίτερων φασματικών χαρακτηριστικών τα οποία οφείλονται στους χημικούς δεσμούς των στερεών , υγρών ή αερίων σωμάτων .

Η ανίχνευση των υλικών εξαρτάται σε μεγάλο βαθμό απο τη φασματική κάλυψη , τη φασματική ανάλυση και το βαθμό του θορύβου των φασματομέτρων αλλά και απ'τη συγκέντρωση του υλικού και την ισχύ των χαρακτηριστικών απορρόφησης αυτού του υλικού στη μετρούμενη περιοχή μήκους κύματος .


Τα υπερφασματικά δεδομένα είναι πολύ μεγάλα σύνολα δεδομενων που απαιτούν νέες μεθόδους επεξεργασίας και συλλέγονται και αναπαριστώνται με τη μορφή ενός κύβου (hypercube) με χωρική πληροφορία στη x και y διάσταση και φασματική στην z .



*Εικ . 12 Υπερφασματικός κύβος του συστήματος AVIRIS (Airborn Visible-InfraRed Imaging Spectrometer)*

## 2.2 Υπερφασματικοί αισθητήρες

- Τα φασματόμετρα απεικόνισης (imaging spectrometers) ή υπερφασματικοί αισθητήρες (hyperspectral sensors), είναι τηλεσκοπικά αισθητήρια όργανα τα οποία συνδυάζουν τη χωρική απεικόνιση ενός αισθητήρα απεικόνισης (imaging sensor) με τις αναλυτικές ικανότητες ενός φασματομέτρου.
- Μπορούν να έχουν έως και εκατοντάδες, πολύ στενές φασματικές ζώνες με φασματική ανάλυση της τάξης των 10 nm ή και μικρότερη.
- Τα φασματόμετρα απεικόνισης παράγουν ένα πλήρες, συνεχές φάσμα για κάθε pixel της εικόνας .
- Το αποτέλεσμα αυτής της υψηλής φασματικής ανάλυσης των φασματομέτρων απεικόνισης είναι η δυνατότητα της ταυτοποίησης υλικών, ενώ με τους ευρείας ζώνης πολυφασματικούς αισθητήρες μπορούσαμε απλά να κάνουμε διακρίσεις μεταξύ υλικών.



Εικ . 13 Οι διαστάσεις ενός υπερφασματικού κύβου

| Satellite Sensors  | Manufacturer   | Number of Bands | Spectral Range             |
|--|--|-----------------|----------------------------|
| FTHSI on MightySat II  | Air Force Research Lab<br><a href="http://www.vs.af.mil/TechProgs/MightySatII">www.vs.af.mil/TechProgs/MightySatII</a> | 256             | 0.35 to 1.05 $\mu\text{m}$ |
| Hyperion on EO-1   | NASA Goddard Space Flight Center<br><a href="http://eo1.gsfc.nasa.gov">eo1.gsfc.nasa.gov</a>                           | 220             | 0.4 to 2.5 $\mu\text{m}$   |
| Airborne Sensors   | Manufacturer   | Number of Bands | Spectral Range             |
| AVIRIS (Airborne Visible Infrared Imaging Spectrometer)      | NASA Jet Propulsion Lab<br><a href="http://makalu.jpl.nasa.gov/">makalu.jpl.nasa.gov/</a>                              | 224             | 0.4 to 2.5 $\mu\text{m}$   |
| HYDICE (Hyperspectral Digital Imagery Collection Experiment) | Naval Research Lab   | 210             | 0.4 to 2.5 $\mu\text{m}$   |

Πίνακας 3 Σημερινοί και πρόσφατοι υπερφασματικοί αισθητήρες



### 2.2.1 Χωρική Ανάλυση

Για τα περισσότερα τηλεσκοπικά όργανα, η απόσταση ανάμεσα στο στόχο που απεικονίζεται και την πλατφόρμα του αισθητήρα παίζει πολύ σημαντικό ρόλο στον καθορισμό του βαθμού λεπτομέρειας της πληροφορίας αλλά και του μεγέθους της περιοχής που απεικονίζεται .

Αισθητήρες σε πλατφόρμες που βρίσκονται πολύ μακριά απ'το στόχο τυπικά απεικονίζουν μεγαλύτερες περιοχές, δεν παρέχουν όμως λεπτομερή πληροφορία. Η λεπτομέρεια που διακρίνουμε σε μία εικόνα εξαρτάται απ'τη χωρική ανάλυση του αισθητήρα και αναφέρεται στο μέγεθος του μικρότερου πιθανού χαρακτηριστικού το οποίο μπορεί να εντοπιστεί .

Η χωρική ανάλυση ενός αισθητήρα εξαρτάται απο έναν παράγοντα ο οποίος ονομάζεται **Instantaneous Field of View (IFOV)** και αντιστοιχεί στην οπτική γωνία του αισθητήρα , και είναι αυτός που καθορίζει το μέγεθος της περιοχής που θα είναι ορατή απο ένα συγκεκριμένο ύψος , μία συγκεκριμένη χρονική στιγμή .

Το μέγεθος της περιοχής αυτής ισούται με το γινόμενο του IFOV επι την απόσταση του εδάφους απ'τον αισθητήρα .

Η απόσταση αυτή ονομάζεται **resolution cell** και καθορίζει τη μέγιστη χωρική ανάλυση ενός αισθητήρα (CCRS 2004) .

### 2.2.2 Φασματική Ανάλυση

Η φασματική ανάλυση αναφέρεται στην ικανότητα ενός αισθητήρα να οροθετεί μικρά διαστήματα μήκους κύματος .Όσο πιο υψηλή είναι η φασματική ανάλυση τόσο πιο στενά είναι τα διαστήματα μήκους κύματος μεταξύ των ζωνών .


Αυτό βέβαια πολλές φορές δημιουργεί άλλου είδους προβλήματα αφού έτσι προκύπτουν περισσότερες επικαλυπτόμενες ζώνες, διαφορετικές ζώνες δηλαδή οι οποίες όμως παρέχουν την ίδια πληροφορία, καθιστώντας πιο δύσκολη την επεξεργασία των δεδομένων (CCRS 2004) .

### 2.3 Φασματικές υπογραφές (Spectral Signatures)

Ένα φάσμα ανάκλασης μας δείχνει την ανάκλαση της ακτινοβολίας απο ένα αντικείμενο σε ένα εύρος μήκους κύματος .

Κάποια υλικά θα ανακλούν κάποια μήκη κύματος ενώ κάποια άλλα θα απορροφούν ακριβώς τα ίδια.

Αυτά τα δείγματα ανάκλασης ή απορρόφησης της ακτινοβολίας (**spectral signatures**) σε ένα εύρος μήκους κύματος μας δίνουν τη δυνατότητα να ταυτοποιήσουμε μοναδικά ένα υλικό.



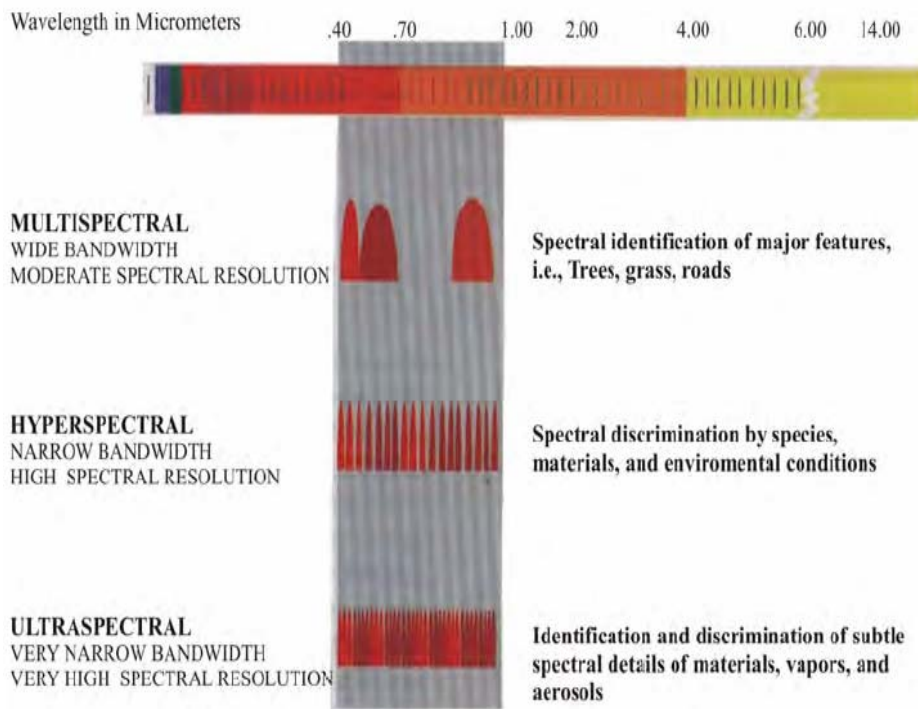
Εικ . 14 Οι φασματικές υπογραφές για τέσσερα διαφορετικά υλικά

## 2.4 Υπερφασματική vs πολυφασματική απεικόνιση


Τα υπερφασματικά δεδομένα μας παρέχουν επαρκή φασματική πληροφορία για την ανίχνευση και το διαχωρισμό μοναδικών υλικών με παρόμοια φασματικά χαρακτηριστικά , παρέχοντας έτσι την προοπτική για πιο ακριβή και λεπτομερή εξαγωγή πληροφορίας απο οποιοδήποτε άλλο τύπο τηλεσκοπικών δεδομένων

Οι περισσότεροι πολυφασματικοί αισθητήρες (π.χ Landsat, IKONOS, και AVHRR) μετρούν την ανάκλαση και/ή την εκπομπή της ακτινοβολίας σε μερικές μόνο ευρείς ζώνες μήκους κύματος οι οποίες διαχωρίζονται απο τμήματα του φάσματος στα οποία δε γίνεται καμιά μέτρηση .

Αντίθετα οι υπερφασματικοί αισθητήρες μετρούν την ακτινοβολία σε μία σειρά απο στενές και συνεχείς ζώνες μήκους κύματος .




Διαγρ . 5 Τεχνικές φασματικής απεικόνισης



**Εικ . 15** Συγκριτική αναπαράσταση των τεχνικών της υπερφασματικής και πολυφασματικής απεικόνισης

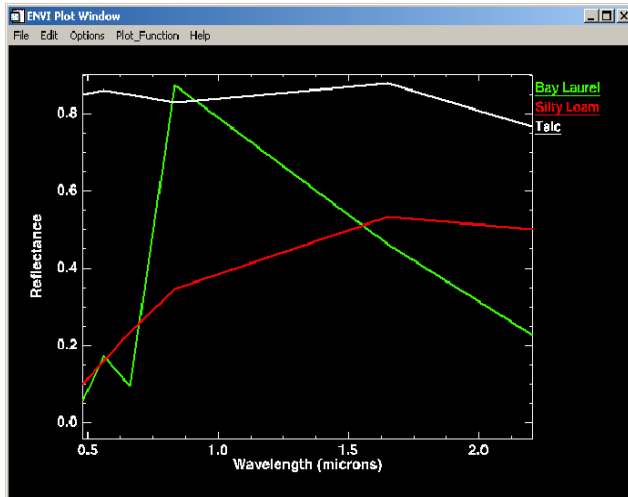
Τα εργαστηριακά φασματοόμετρα μετρούν την ανάκλαση σε πολύ στενές ζώνες μήκους κύματος, έτσι το εξαγόμενο φάσμα εμφανίζεται σαν συνεχής καμπύλη.

Όταν ένα φασματοόμετρο χρησιμοποιείται σε έναν αισθητήρα απεικόνισης οι εξαγόμενες εικόνες θα καταγράφουν ένα φάσμα ανάκλασης για κάθε pixel στην εικόνα.




**Εικ . 16** Η λογική της υπερφασματικής απεικόνισης : Οι εικόνες λαμβάνονται ταυτόχρονα σε 100-200 φασματικές ζώνες. Κάθε pixel σχετίζεται με ένα συνεχές φάσμα το οποίο χρησιμοποιείται για την ταυτοποίηση του υλικού.


Το φάσμα ενός pixel σε μία υπερφασματική εικόνα μοιάζει πάρα πολύ με το φάσμα που θα είχαμε από ένα εργαστηριακό φασματόμετρο έτσι μας παρέχει περισσότερη πληροφορία από μία αντίστοιχη πολυφασματική εικόνα.



*Εικ . 17 Φάσματα ανάκλασης τριών υλικών όπως θα εμφανιζόντουσαν στον πολυφασματικό αισθητήρα του **Landsat 7***



*Εικ . 18 Τα φάσματα για τα ίδια τρία υλικά, μετρημένα από εργαστηριακό φασματόμετρο*

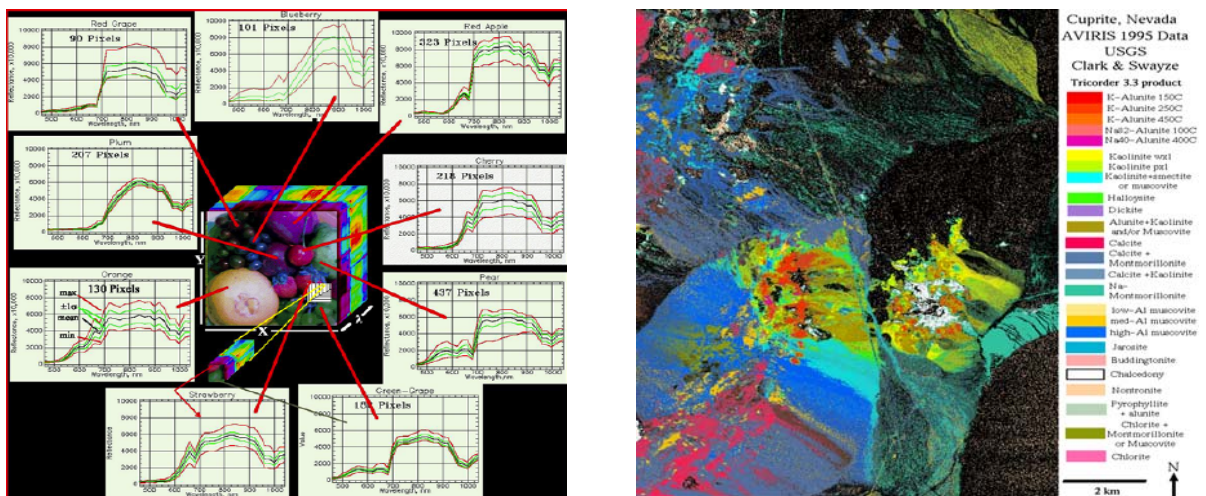


**Εικ . 19** Τα φάσματα ανάκλασης για τα ίδια τρία υλικά, όπως θα εμφανιζόντουσαν απο τον υπερφασματικό αισθητήρα του AVIRIS. Τα κενά στις καμπύλες αντιστοιχούν σε μήκη κύματος στα οποία η ατμόσφαιρα απορροφά τόσο πολύ φως που κανένα αξιόπιστο σήμα δεν λαμβάνεται απο την επιφάνεια.

## 2.5 Εφαρμογές υπερφασματικής απεικόνισης

Η υπερφασματική τηλεπισκόπηση έχει χρησιμοποιηθεί ως επι το πλείστον απο γεωλόγους για τη χαρτογράφηση ορυκτών στην επιφάνεια της γης (Clark et al., 1992, 1995) και τον εντοπισμό ιδιοτήτων του εδάφους όπως υγρασία, αλμυρότητα και οργανική περιεκτικότητα .

Επίσης απο φυτολόγους και γεωπόνους για την ταυτοποίηση ειδών βλάστησης (Clark et al., 1995), μελέτη της χημικής σύνθεσης φυτών (Aber και Martin, 1995) και εντοπισμό ασθενειών της βλάστησης (Merton, 1999) αλλά και απο πλήθος άλλων επιστημονικών πεδίων συμπεριλαμβανομένης και της ιατρικής στα πλαίσια της οπτικής βιοψίας ως μίας μη επεμβατικής διαγνωστικής μεθόδου .



**Εικ . 20** Εφαρμογές της υπερφασματικής απεικόνισης στη φυτοπαθολογία και τη γεωλογία

# Κεφάλαιο 3<sup>ο</sup>

## *Επεξεργασία των υπερφασματικών δεδομένων*

### 3.1 Εισαγωγή

Όπως ήδη δείξαμε στην εισαγωγή, κάνοντας μία συνοπτική περιγραφή της οργάνωσης ενός συστήματος υπερφασματικής απεικόνισης, το σύστημα μπορεί να διαιρεθεί σε τρία βασικά κομμάτια : την προεπεξεργασία των δεδομένων (pre-processing), την εξαγωγή των χαρακτηριστικών (feature extraction), και τέλος την ταξινόμηση (classification).

Στη συνέχεια θα εξετάσουμε κάποια βασικά θέματα που αφορούν στην προεπεξεργασία και θα εμβαθύνουμε στις διάφορες τεχνικές εξαγωγής των χαρακτηριστικών και ελαχιστοποίησης των δεδομένων, πριν προχωρήσουμε στο τελικό στάδιο της ταξινόμησης .

### 3.2 Προεπεξεργασία

Η προεπεξεργασία γενικά προηγείται της ανάλυσης των δεδομένων ή της εξαγωγής της πληροφορίας και σκοπός της είναι η μείωση του θορύβου ή ο εμπλουτισμός κάποιας όψης των δεδομένων . Υπάρχει μεγάλος αριθμός τύπων προεπεξεργασίας που εφαρμόζονται στα δεδομένα.

Κάποια παραδείγματα είναι : Ραδιομετρική βαθμονόμηση (Radiometric Calibration) , Ατμοσφαιρική Διόρθωση (Atmospheric Correction) , Εμπλουτισμός του Contrast και Image Registration .

#### 3.2.1 Ατμοσφαιρική Διόρθωση

Πριν απο την επαφή της με την επιφάνεια της γης η ακτινοβολία που χρησιμοποιείται στην τηλεπισκόπηση διανύει μία μεγάλη απόσταση μέσα στην ατμόσφαιρα . Εκεί υπάρχουν σωματίδια και αέρια τα οποία την επηρεάζουν μέσω των μηχανισμών της σκέδασης και της απορρόφησης (Landgrebe 2003) .

Η σκέδαση συμβαίνει όταν σωματίδια και μεγάλα μόρια αερίων αλληλεπιδρούν με την ηλεκτρομαγνητική ακτινοβολία, με αποτέλεσμα την ανακατεύθυνσή της, και ο βαθμός κατά τον οποίο συμβαίνει αυτό εξαρτάται απ'το μήκος κύματος της ακτινοβολίας, τη συγκέντρωση των σωματιδίων αυτών και την απόσταση που διανύει η ακτινοβολία μέσα στην ατμόσφαιρα .

Η απορρόφηση συμβαίνει όταν κάποια στοιχεία της ατμόσφαιρας απορροφούν ενέργεια απ'την ακτινοβολία, σε κάποια μήκη κύματος .

Το όζον, το διοξείδιο του άνθρακα και οι υδρατμοί είναι τα στοιχεία που ευθύνονται περισσότερο για το φαινόμενο αυτό .

Ένα επίσης σημαντικό πρόβλημα είναι και η σκέδαση της ακτινοβολίας απο αντικείμενα γειτονικά του αντικειμένου που μας ενδιαφέρει και τα οποία έχουν διαφορετικά χαρακτηριστικά ανάκλασης .

Όλα τα παραπάνω συντελούν στη δημιουργία ενός προβλήματος :

Οι τηλεσκοπικές εικόνες δεν περιλαμβάνουν πληροφορίες μόνο για την περιοχή που μας ενδιαφέρει αλλά και για την ατμόσφαιρα, καθιστώντας έτσι τη διαδικασία της ατμοσφαιρικής διόρθωσης ένα πολύ σημαντικό κομμάτι της προεπεξεργασίας των δεδομένων .

Για να εξουδετερώσουμε τις επιδράσεις αυτές της ατμόσφαιρας, ιδιότητες όπως η ποσότητα των υδρατμών, η κατανομή των στερεών σωματιδίων μέσα στα αέρια σώματα και η ορατότητα του πεδίου πρέπει να είναι γνωστές .

Επειδή όμως απ'ευθείας μετρήσεις αυτών των ατμοσφαιρικών ιδιοτήτων δεν είναι συχνά διαθέσιμες, έχουν αναπτυχθεί διάφορες τεχνικές για την εξαγωγή τους απ'τα ίδια τα υπερφασματικά δεδομένα, αφού κάθε pixel σε μία υπερφασματική εικόνα περιέχει μία ξεχωριστή μέτρηση της ζώνης απορρόφησης των ατμοσφαιρικών υδρατμών (Adler-Golden 98) .

### 3.2.2 Γεωμετρική Διόρθωση

Λόγω της γεωμετρική πολυπλοκότητας της διαδικασίας πρόσκτησης (acquisition) , οι τηλεσκοπικές δορυφορικές εικόνες επηρεάζονται απο διάφορους τύπους θορύβου και δεν μπορούν να χρησιμοποιηθούν για την επικάλυψη σε τοπογραφικούς χάρτες .

Ο θόρυβος αυτός οφείλεται :

- Στην καμπυλότητα και το ανάγλυφο της επιφάνειας της γης
- Στη σχετική κίνηση μεταξύ δορυφόρου και γης κατα τη διάρκεια της πρόσκτησης
- Στις μεταβολές της θέσης και της ταχύτητας του δορυφόρου στην τροχιά του
- Στη χωρική ανάλυση του αισθητήρα και την οπτική γωνία τη στιγμή της πρόσκτησης

Η γεωμετρική διόρθωση της εικόνας είναι μια διαδικασία η οποία παράγει νέες εικόνες που χαρακτηρίζονται απο τις ιδιότητες της κλίμακας και της προέκτασης όπως και οι τοπογραφικοί χάρτες .

Μία μέθοδος που χρησιμοποιείται συχνά για την γεωμετρική διόρθωση είναι η μέθοδος **ground control points** η οποία βασίζεται σε μαθηματικές/στατιστικές σχέσεις μεταξύ των συντεταγμένων των pixels της εικόνας και σε μία αναφορική χαρτογραφία .

### 3.2.3 Image Registration

Η γεωμετρική διόρθωση μιας εικόνας με την έννοια της μεθόδου ground control points μπορεί επίσης να χρησιμοποιηθεί για την τροποποίηση μιας εικόνας έτσι ώστε να επικαλύπτει μια εικόνα αναφοράς .

Αυτός ο μετασχηματισμός ονομάζεται **image registration** και είναι πολύ χρήσιμος στην επικάλυψη των εικόνων όταν δεν είναι διαθέσιμοι αρκετοί τοπογραφικοί χάρτες .

Σε περίπτωση που υπάρχουν αρκετοί τοπογραφικοί χάρτες και η εικόνα αναφοράς είναι γεωμετρικά διορθωμένη τότε η ευθυγραμμισμένη εικόνα (registered) είναι και αυτή γεωμετρικά διορθωμένη . Παρ'όλα αυτά είναι πιο ασφαλές να διορθώνουμε γεωμετρικά μία-μία τις εικόνες απ'το να τις ευθυγραμμίζουμε με μία διορθωμένη εικόνα αναφοράς .

### 3.3 Ελαχιστοποίηση δεδομένων (Data Reduction)

Τα δεδομένα υπερφασματικής απεικόνισης αποτελούνται από εκατοντάδες κανάλια και οδηγούν σε εκτεταμένο χρόνο εκτέλεσης. Όταν ακόμη ο αριθμός των καναλιών διπλασιάζεται ο χρόνος εκτέλεσης πολλαπλασιάζεται. Τα υψηλά συσχετιζόμενα κανάλια μπορούν να προκαλέσουν ακόμα και κατάρρευση του συστήματος ταξινόμησης.

|                                | AVIRIS [JPL]<br>(typical sample) | TRWIS [TRW] | HYDICE [Hughes]<br>(typical sample) | Future sensor array |
|--------------------------------|----------------------------------|-------------|-------------------------------------|---------------------|
| Image resolution<br>(pixels)   | 614 x 512                        | 512 x 512   | 320 x 240                           | 1000 x 1000         |
| *Dynamic range<br>(bits/pixel) | 12                               | 12          | 12                                  | 12                  |
| Spectral Bands                 | 224                              | 384         | 210                                 | 200                 |
| Image Size<br>(MB)             | 105                              | 150.9       | 24.1                                | 300                 |

*Πίνακας 4 Οι προδιαγραφές κάποιων αισθητήρων υπερφασματικής απεικόνισης*

Για αυτούς τους λόγους είναι απαραίτητη η χρήση αποτελεσματικών μεθόδων εξαγωγής των χαρακτηριστικών και ελαχιστοποίησης των διαστάσεων του υπερφασματικού πεδίου (**feature extraction, band reduction**).

Οι μέθοδοι αυτοί μπορεί να αφαιρέσουν μικρές διαφορές στα φάσματα μεταξύ των υλικών οι οποίες όμως παίζουν σημαντικό ρόλο στην ταξινόμηση χαρακτηρίζοντας κάποια υλικά.

Για παράδειγμα η επίδραση κάποιων τύπων αποβλήτων σε ένα φάσμα ανάκλασης βλάστησης γίνεται αντιληπτή μόνο σε λίγες και συγκεκριμένες ζώνες μήκους κύματος γι' αυτό και η διαδικασία αυτή απαιτεί πολύ προσοχή.

Όταν χρησιμοποιούμε αλγόριθμους όπως ο **Spectral Angle Mapper** η εξαγωγή των χαρακτηριστικών δεν είναι απαραίτητη, γιατί λαμβάνουμε υπόψιν μας ολόκληρο το φάσμα ανάκλασης των δεδομένων.

Βασιζόμενοι στο γεγονός ότι γειτονικές φασματικές ζώνες είναι συχνά ύψηλα συσχετιζόμενες, μπορούμε να μειώσουμε τη διαστατικότητα χωρίς σημαντική επιρροή στην αναπαράστασή τους.

Βασικά δύο προσεγγίσεις χρησιμοποιούνται γι' αυτό το σκοπό : **Band Selection** και **Feature Extraction**.

Στην πρώτη προσέγγιση επιλέγουμε τις «καλύτερες» ζώνες βασιζόμενοι σε διάφορα κριτήρια.

Στη δεύτερη μαθηματικά και στατιστικά μοντέλα εφαρμόζονται στα δεδομένα για να επιτύχουμε την καλύτερη αναπαράσταση των αρχικών δεδομένων χωρίς το συσχετισμό μεταξύ των ζωνών οπότε μειώνοντας τις διαστάσεις.



### 3.3.1 Εξαγωγή Χαρακτηριστικών (Feature Extraction)

Η εξαγωγή χαρακτηριστικών είναι η αναγνώριση χαρακτηριστικών ή αντικειμένων του πραγματικού κόσμου μέσα στα χωρικά δεδομένα, συγκεκριμένα στα δεδομένα τηλεπισκόπησης .

Ο βασικός σκοπός της διαδικασίας εξαγωγής χαρακτηριστικών είναι να μπορέσει να χαρακτηρίσει ένα αντικείμενο κάνοντας αριθμητικές μετρήσεις. Τα “καλά” χαρακτηριστικά είναι αυτά των οποίων οι τιμές είναι παρόμοιες για αντικείμενα που ανήκουν στην ίδια κατηγορία και διαφορετικές για αντικείμενα που ανήκουν σε διαφορετική .

Συνήθως ένα χαρακτηριστικό δεν είναι αρκετό για να διαφοροποιήσει αντικείμενα που ανήκουν σε διαφορετικές κατηγορίες .

Όπως προαναφέραμε η εξαγωγή των χαρακτηριστικών είναι ένα προαιρετικό στάδιο της διαδικασίας ταξινόμησης και εξυπηρετεί μόνο , σαν χαμηλού επιπέδου προεπεξεργασία της εικόνας , στη μείωση της χωρικής ή φασματικής διαστατικότητας της .

Επιτυγχάνει, με τη χρήση κάποιων χωρικών φίλτρων ή με φασματικούς μετασχηματισμούς η πολύ απλά με την επιλογή ενός υποσυνόλου των φασματικών ζωνών, να μειώσει τον αριθμό των δεδομένων ή/και να εμπλουτίσει τα υπερφασματικά χαρακτηριστικά,.

Σε αυτό το στάδιο η υπερφασματική εικόνα έχει μετατραπεί σε μια εικόνα χαρακτηριστικών .

### 3.3.2 Ο χώρος χαρακτηριστικών (Feature Space)

Για καλύτερη κατανόηση της διαδικασίας ταξινόμησης θα εισάγουμε έναν νέο όρο : το χώρο χαρακτηριστικών .

Οι αισθητήρες των δορυφόρων μετράνε την ανακλώμενη ακτινοβολία , απ’την επιφάνεια της γης , και τη μετατρέπουν σε ψηφιακές τιμές (Digital Numbers) .

Στην πλειοψηφία τους αυτές οι τιμές είναι θετικοί , ακέραιοι αριθμοί απο 0 ως 255 .

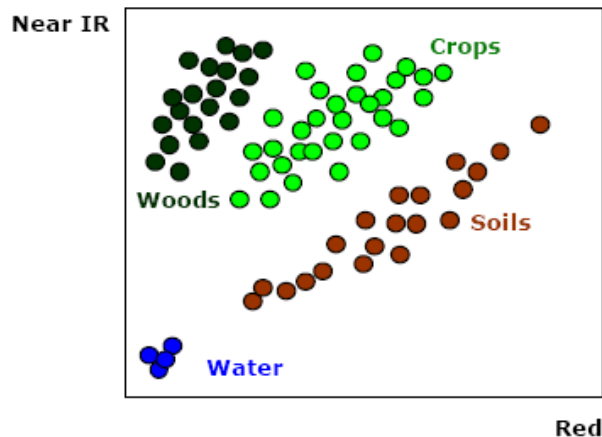
Κατά συνέπεια , κάθε pixel της εικόνας χαρακτηρίζεται απο μία σειρά ψηφιακών τιμών , μία για κάθε φασματική ζώνη .

Αυτές οι σειρές των τιμών μπορούν να αναπαρασταθούν ως συντεταγμένες σημείων σε ένα πολυδιάστατο Καρτεσιανό χώρο, του οποίου οι άξονες αναπαριστούν τις φασματικές ζώνες .

Αυτός ο χώρος ονομάζεται **χώρος χαρακτηριστικών** (feature space) .

Σημειώνουμε εδώ οτι σ’αυτή την αναπαράσταση δεν περιλαμβάνεται η πληροφορία σχετικά με τη θέση του pixel στην εικόνα .

Για να κατανοήσουμε τη χρησιμότητα του χώρου χαρακτηριστικών ας θεωρήσουμε μία διδιάστατη αναπαράσταση του, χρησιμοποιώντας τις ζώνες του κόκκινου και του κοντινού υπέρυθρου .



*Εικ . 21 Δισδιάστατη αναπαράσταση διαφόρων υλικών στο χώρο χαρακτηριστικών του κόκκινου και κοντινού υπέρυθρου .*

Όπως έχουμε ήδη πει παρόμοια υλικά χαρακτηρίζονται απο κοντινές φασματικές υπογραφές , καμπύλες δηλαδή φασματικής ανάκλασης ή αλλιώς , παρόμοιες ψηφιακές τιμές σε κάθε φασματική ζώνη .

Όπως παρατηρούμε και στην παραπάνω εικόνα , τα pixels που αντιστοιχούν στα ίδια υλικά είναι ομαδοποιημένα μαζί , στο χώρο χαρακτηριστικών για τις παραπάνω ζώνες .

Έτσι το υλικό που αντιστοιχεί σε κάθε ομάδα μπορεί εύκολα να ταυτοποιηθεί χρησιμοποιώντας την φασματική του υπογραφή .

- Το νερό έχει χαμηλό βαθμό ανάκλασης και στις δύο ζώνες του κόκκινου και κοντινού υπέρυθρου , άρα τα αντίστοιχα pixels έχουν χαμηλές τιμές και βρίσκονται κοντά στην αρχή των αξόνων .

- Η ανάκλαση των αποβλήτων στο κοντινό υπέρυθρο είναι ελαφρώς υψηλότερη απ'ότι στο κόκκινο και έτσι τα αντίστοιχα pixels βρίσκονται κοντά στη διαγώνια γραμμή του γράφου .

- Η επιφάνειες με βλάστηση έχουν υψηλότερο βαθμό ανάκλασης στο κοντινό υπέρυθρο απ'ότι στο κόκκινο έτσι τα αντίστοιχα σημεία βρίσκονται πάνω αριστερά στο χώρο χαρακτηριστικών .

Το πρόβλημα της ταυτοποίησης μιας επιφάνειας έχει αναχθεί πλέον στην ανάθεση των pixels σε μία απ' τις παραπάνω ομάδες στο χώρο χαρακτηριστικών .

Δυστυχώς η αναπαράσταση μιας εικόνας στο χώρο χαρακτηριστικών δεν είναι ποτέ τόσο ακριβής όσο στο παραπάνω παράδειγμα . Πολλά απ' τα pixels μίας εικόνας αντιστοιχούν σε περισσότερες απο μία επιφάνειες οπότε παρουσιάζεται και το φαινόμενο των **mixed pixels** κάτι που θα δούμε στη συνέχεια, εξετάζοντας παράλληλα και κάποιες τεχνικές **spectral unmixing** .

### 3.4 Μαθηματικό υπόβαθρο

Σε αυτό το σημείο κρίνεται απαραίτητη η γνώση ενός στοιχειώδους μαθηματικού υποβάθρου το οποίο θα μας βοηθήσει στην κατανόηση πολλών απ'τους αλγορίθμους που θα εξετάσουμε αναλυτικά στη συνέχεια .

Είναι λιγότερο σημαντικό να θυμόμαστε την ακριβή διαδικασία μιας μαθηματικής τεχνικής απ'το να κατανοήσουμε τους λόγους για τους οποίους χρησιμοποιούμε την τεχνική αυτή και τί είναι αυτό που μας λένε τα αποτελέσματα για τα δεδομένα μας .

#### 3.4.1 Στατιστική

Το αντικείμενο της στατιστικής βασίζεται στην ιδέα της ανάλυσης ενός συνόλου δεδομένων με όρους που καθορίζονται απο τις σχέσεις μεταξύ των μεμονωμένων στοιχείων του συνόλου αυτού. Θα εξετάσουμε κάποιους απο αυτούς τους όρους για ένα σύνολο δεδομένων και θα δούμε τι μας δείχνουν για τα ίδια τα δεδομένα .

#### 3.4.2 Τυπική Απόκλιση (Standard Deviation)

Για να κατανοήσουμε την τυπική απόκλιση χρειαζόμαστε ένα σύνολο δεδομένων. Όπως συνηθίζεται στη στατιστική θα χρησιμοποιήσουμε ένα δείγμα ενός πληθυσμού και θα αρκεστούμε στο να δουλέψουμε σ'αυτό το δείγμα παρά σε ολόκληρο τον πληθυσμό .

Έτσι θεωρούμε ένα σύνολο δεδομένων  $X$  με στοιχεία  $X_1, X_2 \dots X_n$  με  $n$  τον αριθμό των στοιχείων του συνόλου , και το παρακάτω δείγμα του συνόλου αυτού :

$$X = [ 1 2 4 6 12 15 25 45 68 67 95 98 ]$$

Ένα απ'τα πρώτα πράγματα που μπορούμε να κάνουμε σε ένα τέτοιο δείγμα δεδομένων είναι να υπολογίσουμε το **μέσο** (mean) του δείγματος αυτού που δίνεται απ'τον παρακάτω τύπο :

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

Αμέσως όμως καταλαβαίνουμε οτι το μέσο απο μόνο του δε μας δίνει αρκετή πληροφορία για τα δεδομένα και μάλιστα είναι πιθανό να είναι το ίδιο και για δύο διαφορετικά σύνολα , όπως για παράδειγμα τα σύνολα

$$[ 0 8 12 20 ] \text{ και } [ 8 9 11 12 ]$$

Η διαφορά ανάμεσα σ'αυτά τα δύο σύνολα είναι η διαφορετική κατανομή των δεδομένων τους. Έτσι η τυπική απόκλιση ενός συνόλου δεδομένων είναι η μέτρηση του τρόπου με τον οποίο είναι κατανεμημένα τα δεδομένα στο σύνολο αυτό και ορίζεται ως εξής :

**“ Τυπική απόκλιση ενός συνόλου δεδομένων είναι η μέση απόσταση του μέσου του συνόλου προς κάθε σημείο του συνόλου αυτού ”.**

Ένας τρόπος υπολογισμού της τυπικής απόκλισης είναι να υπολογίσουμε το άθροισμα των τετραγώνων των αποστάσεων κάθε σημείου του συνόλου με το μέσο αυτού, διαιρεμένο με το πλήθος  $n-1$  και να βρούμε την τετραγωνική ρίζα του λόγου αυτού :

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)}}$$

Το  $n-1$  στον παρονομαστή οφείλεται στο ότι υπολογίζουμε την τυπική απόκλιση για ένα δείγμα του πληθυσμού και όχι για ολόκληρο τον πληθυσμό.

Στην περίπτωση του υπολογισμού για ολόκληρο τον πληθυσμό θα διαιρούσαμε το άθροισμα με  $n$  και όχι με  $n-1$

### 3.4.3 Διακύμανση (Variance)

Η διακύμανση είναι ένας άλλος τρόπος μέτρησης του τρόπου κατανομής των δεδομένων σε ένα σύνολο δεδομένων και δίνεται απ' τον παρακάτω τύπο :

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)}$$

Παρατηρούμε ότι η διακύμανση είναι απλώς το τετράγωνο της τυπικής απόκλισης και αυτός μάλιστα είναι και ο συμβολισμός της. Και οι δύο είναι μονάδες μέτρησης του τρόπου κατανομής των δεδομένων με πιο συνηθισμένη την τυπική απόκλιση. Ο ορισμός όμως της διακύμανσης θα μας βοηθήσει να ορίσουμε και να κατανοήσουμε τη συμμεταβλητότητα.

### 3.4.4 Συμμεταβλητότητα (Covariance)

Οι δύο προηγούμενες μονάδες μέτρησης ενεργούν σε μία μόνο διάσταση. Έτσι αν είχαμε ένα πολυδιάστατο σύνολο δεδομένων θα μπορούσαμε να υπολογίσουμε την τυπική απόκλιση μόνο για μία διάσταση ξεχωριστά. Είναι χρήσιμο παρ' όλα αυτά να μπορούμε να δούμε πως διαφοροποιούνται οι διαστάσεις απ' το μέσο, σε σχέση η μια απ' την άλλη.

Ένα τέτοιο μέτρο είναι η συμμεταβλητότητα. Η συμμεταβλητότητα μετριέται πάντα μεταξύ δύο διαστάσεων. Αν υπολογίσουμε τη συμμεταβλητότητα μεταξύ μιας διάστασης και του εαυτού της θα πάρουμε τη διακύμανσή της.

Ο τύπος της συμμεταβλητότητας είναι παρόμοιος με αυτόν της διακύμανσης.

Η διακύμανση μπορεί να γραφτεί και :

$$var(X) = \frac{\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})}{(n-1)}$$

Έτσι λαμβάνοντας υπόψιν μας τα προηγούμενα η συμμεταβλητότητα δίνεται απ' τον τύπο :

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n - 1)}$$

Αν η τιμή της συμμεταβλητότητας ανάμεσα σε δύο διαστάσεις είναι αρνητική τότε όταν η μία αυξάνεται η άλλη θα μειώνεται . Στην περίπτωση που η συμμεταβλητότητα είναι ίση με μηδέν τότε αυτές οι δύο διαστάσεις είναι τελείως ανεξάρτητες μεταξύ τους.

### 3.4.5 Πίνακας Συμμεταβλητότητας (Covariance Matrix)

Είδαμε οτι η συμμεταβλητότητα μετρείται πάντα μεταξύ δύο διαστάσεων .

Έτσι για ένα τρισδιάστατο σύνολο δεδομένων  $(x, y, z)$  θα μπορούσαμε να υπολογίσουμε τις  $cov(x, y)$  ,  $cov(x, z)$  και  $cov(y, z)$  .

Γενικά για ένα n-διάστατο σύνολο δεδομένων θα μπορούσαμε να υπολογίσουμε

$$\frac{n!}{(n-2)! * 2}$$

διαφορετικές τιμές συμμεταβλητότητας .

Έτσι ο ορισμός του πίνακα συμμεταβλητότητας για ένα n-διάστατο σύνολο δεδομένων είναι :

$$C^{n \times n} = (c_{i,j}, c_{i,j} = cov(Dim_i, Dim_j))$$

όπου  $C^{n \times n}$  είναι ένας τετραγωνικός πίνακας  $n \times n$  και  $Dim_x$  είναι η  $x$  διάσταση , για παράδειγμα το στοιχείο  $2 \times 3$  του πίνακα θα είναι η συμμεταβλητότητα μεταξύ της  $2^{ης}$  και  $3^{ης}$  διάστασης.

Εύκολα διαπιστώνουμε οτι αφού πρόκειται για τετραγωνικό πίνακα τα στοιχεία της κύριας διαγωνίου του πίνακα θα είναι η διακύμανση της κάθε διάστασης.

Επίσης αφού απ' τον τύπο της συμμεταβλητότητας βλέπουμε οτι  $cov(x, y) = cov(y, x)$  διαπιστώνουμε οτι ο πίνακας συμμεταβλητότητας είναι ένας συμμετρικός πίνακας .

### 3.4.6 Ιδιοδιανύσματα και Ιδιοτιμές (Eigenvectors , Eigenvalues)

Μαθηματικά ένα διάνυσμα  $v_\lambda$  είναι ένα ιδιοδιάνυσμα , και  $\lambda$  η αντίστοιχη ιδιοτιμή του , ενός μετασχηματισμού  $T$  αν η εξίσωση :

$$T(v_\lambda) = \lambda v_\lambda$$

αληθεύει , όταν το  $T (v_\lambda )$  είναι το διάνυσμα που παράγεται εφαρμόζοντας τον μετασχηματισμό  $T$  στο  $v_\lambda$  .

Για να το κατανοήσουμε καλύτερα ας υποθέσουμε ότι έχουμε τον πίνακα μετασχηματισμού  $A$

$$\begin{pmatrix} 2 & 3 \\ 2 & 1 \end{pmatrix}$$

και το διάνυσμα  $t$

$$\begin{pmatrix} 3 \\ 2 \end{pmatrix}$$

ο πολλαπλασιασμός μεταξύ αυτών των δύο θα μας δώσει :

$$\begin{pmatrix} 2 & 3 \\ 2 & 1 \end{pmatrix} \times \begin{pmatrix} 3 \\ 2 \end{pmatrix} = \begin{pmatrix} 12 \\ 8 \end{pmatrix} = 4 \times \begin{pmatrix} 3 \\ 2 \end{pmatrix}$$

το αποτέλεσμα είναι το αρχικό διάνυσμα μετατοπισμένο απ'την αρχική του θέση χωρίς όμως να έχει αλλάξει η διεύθυνση του.

Έτσι το διάνυσμα  $t$  και όλα τα πολλαπλάσιά του , αφού δεν έχει σημασία το μήκος του διανύσματος αλλά η διεύθυνσή του , θα είναι ένα ιδιοδιάνυσμα του πίνακα  $A$  .

Ο παράγοντας κατα τον οποίο μετατοπίστηκε το αρχικό διάνυσμα  $t$  μετά τον πολλαπλασιασμό με τον τετραγωνικό πίνακα  $A$  αποτελεί την ιδιοτιμή του ιδιοδιανύσματος και στη συγκεκριμένη περίπτωση είναι το 4 .

Ένα σημαντικό εργαλείο για τον υπολογισμό των ιδιοτιμών ενός τετραγωνικού πίνακα είναι το **χαρακτηριστικό πολυώνυμο** .

Αν θεωρήσουμε  $\lambda$  μία ιδιοτιμή ενός πίνακα  $A$  τότε το σύστημα των γραμμικών εξισώσεων  $(A - \lambda I) v = 0$  (όπου  $I$  ο μοναδιαίος πίνακας) έχει μία μη μηδενική λύση  $v$  (ένα ιδιοδιάνυσμα) και άρα ισοδυναμεί με την ορίζουσα  $\det(A - \lambda I) = 0$  .

Έτσι οι ρίζες του πολυωνύμου  $p(\lambda) = \det(A - \lambda I)$  είναι οι ιδιοτιμές του πίνακα  $A$  και το πολυώνυμο αυτό είναι το χαρακτηριστικό πολυώνυμο .

Όλες οι ιδιοτιμές ενός πίνακα  $A$  μπορούν να υπολογιστούν λύνοντας την εξίσωση  $pA(\lambda) = 0$  , άρα ένας πίνακας  $A$  ,  $n \times n$  θα έχει το πολύ  $n$  ιδιοτιμές .

Γνωρίζοντας τις ιδιοτιμές  $\lambda$  ενός πίνακα  $A$  τα αντίστοιχα ιδιοδιανύσματα μπορούν να βρεθούν λύνοντας την εξίσωση  $(A - \lambda I) v = 0$  .

Μία σημαντική ιδιότητα των ιδιοδιανυσμάτων είναι ότι είναι ορθογώνια μεταξύ τους ανεξάρτητα με τον αριθμό των διαστάσεων που έχουμε .

Αυτό είναι πολύ σημαντικό γιατί μας δίνεται η δυνατότητα να εκφράσουμε τα δεδομένα με όρους αυτά τα κάθετα ιδιοδιανύσματα . Αυτό αποτελεί και τη βάση στην οποία στηρίζεται η Principal Component Analysis .

### 3.5 Αλγόριθμοι εξαγωγής χαρακτηριστικών

Οι ακόλουθοι αλγόριθμοι είναι αντιπροσωπευτικοί των **feature extraction** προσεγγίσεων που χρησιμοποιούνται συνήθως στην τηλεπισκόπηση :

- **Principal Component Analysis (PCA)**
- **Independent Component Analysis (ICA)**
- **Projection Pursuit (PP)**
- **Feedback Classification Algorithm (FCA)**

#### 3.5.1 Principal Component Analysis

Τα βήματα του αλγόριθμου της **Principal Component Analysis** είναι τα εξής :

1. Υπολόγισε τον πίνακα συμμεταβλητότητας (covariance matrix) για τα δεδομένα εισόδου

$$C^{n \times n} = (c_{i,j}, c_{i,j} = cov(Dim_i, Dim_j))$$

2. Υπολόγισε τα ιδιοδιανύσματα και τις ιδιοτιμές του πίνακα συμμεταβλητότητας.

$$[V D]=eig(cov\_matrix)$$

3. Ταξινόμησε τα ιδιοδιανύσματα σε αντιστοίχιση με τη φθίνουσα σειρά των ιδιοτιμών τους.
4. Πρόβαλε τα δεδομένα εισόδου πάνω στα principal components.

Η Principal Component Analysis (PCA) είναι μια συνηθισμένη τεχνική για δεδομένα με πολλαπλές μεταβλητές. Είναι μια διαδικασία μετασχηματισμού ενός συνόλου συσχετιζομένων μεταβλητών σε ένα σύνολο μη συσχετιζομένων μεταβλητών.

Αυτός ο μετασχηματισμός είναι στην ουσία μια περιστροφή των αρχικών αξόνων σε διαφορετικούς προσανατολισμούς οι οποίοι είναι ορθογώνιοι μεταξύ τους οπότε και δεν υπάρχει συσχετισμός μεταξύ των μεταβλητών.

Τα δεδομένα στην υπερφασματική απεικόνιση αναπαριστώνται σαν ένας πίνακας στον οποίο οι γραμμές αναπαριστούν τα pixels και οι στήλες τα μήκη κύματος ή τις φασματικές ζώνες. Αν έχουμε μία  $n \times n$  εικόνα με  $N$  ζώνες ο πίνακας δεδομένων θα έχει  $n^2$  γραμμές και  $N$  στήλες. Έτσι υπολογίζουμε τον **πίνακα συμμεταβλητότητας (covariance matrix)** για το σύνολο των δεδομένων.

Ο τελικός πίνακας θα είναι διαστάσεων  $N \times N$  και θα παρέχει τη σχέση μεταξύ των φασματικών ζωνών. Για έναν συμμετρικό πίνακα όπως ο πίνακας συσχετιστικότητας (covariance matrix) η ορθογώνια βάση μπορεί να βρεθεί αν βρούμε τις **ιδιοτιμές** και τα **ιδιοδιανύσματά** του.


Ένα σύνολο από  $N$  ιδιοτιμές  $(\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_{n-1}, \lambda_n)$  λαμβάνεται απ' τον πίνακα συσχετιστικότητας. Κάθε μία απ' αυτές τις ιδιοτιμές έχει ένα αντίστοιχο ιδιοδιάνυσμα που είναι ορθογώνιο με όλα τα υπόλοιπα.

Αν οι ιδιοτιμές διαταχθούν σε φθίνουσα σειρά το διάνυσμα που συνδέεται με τη μεγαλύτερη τιμή θα περιέχει την κατεύθυνση της μεγαλύτερης **διακύμανσης (variance)** των δεδομένων.

Αφού τα πρώτα  $K$  διανύσματα αναπαριστούν μία σημαντική ποσότητα των διακυμάνσεων σε ολόκληρο το σύνολο μπορούμε να ελαχιστοποιήσουμε τη διαστατικότητα των αρχικών pixels προβάλλοντας το καθένα απ' αυτά στα πρώτα  $K$  ορθογώνια διανύσματα.

Έτσι μειώνουμε τη διαστατικότητα από  $N$  σε  $K$  με αποτέλεσμα την αξιοσημείωτη μείωση σε πολυπλοκότητα και υπολογιστικό κόστος.

Μια απλή αναπαράσταση των principal components φαίνεται παρακάτω :



**Διαγρ . 6** Αναπαράσταση των *Principal Components*

Έστω ότι έχουμε δύο επικαλυπτόμενες τάξεις και δύο φασματικές ζώνες όπως φαίνεται στο διάγραμμα .

Επίσης βλέπουμε και το μονοδιάστατο ιστόγραμμα για τα δεδομένα των δύο ζωνών. Κάθε ιστόγραμμα μας δείχνει μόνο μία κορυφή οπότε είναι αδύνατο να διαχωρίσουμε τις δύο τάξεις βασιζόμενοι σ' αυτά.

Αν όμως μία νέα ζώνη σχηματιστεί κατά μήκος της διεύθυνσης της μέγιστης διακύμανσης της έντασης τότε οι δύο κορυφές θα εμφανιστούν στο ιστόγραμμα αυτής της νέας ζώνης.



Αφού οι δύο άξονες είναι μεταξύ τους ορθογώνιοι άλλη μια νέα ζώνη σχηματίζεται με τον άξονά της κάθετο στην πρώτη. Αυτή η δεύτερη νέα ζώνη μας δείχνει ένα ιστόγραμμα στο οποίο τα pixels είναι συγκεντρωμένα σε ένα πολύ στενό εύρος εντάσεων.

Με άλλα λόγια, η πρώτη νέα ζώνη περιέχει την περισσότερη απ' την πληροφορία της εικόνας σε αντίθεση με την δεύτερη, οπότε στην ταξινόμηση θα χρησιμοποιήσουμε μόνο αυτήν και θα απορίψουμε την άλλη. Αυτό μειώνει τις διαστάσεις από δύο σε μία. Οι δύο νέες αυτές ζώνες ονομάζονται **principal components**.

### 3.5.2 Feedback Classification Algorithm

Ο εντοπισμός των «καλύτερων» ζωνών, αναλύοντας όλους τους πιθανούς συνδυασμούς, είναι υπολογιστικά εξοντωτικός. Ο αριθμός των πιθανών συνδυασμών αυξάνεται εκθετικά όσο η αυξάνεται η διαστατικότητα, με αποτέλεσμα αυτή η αναζήτηση να γίνεται μη πρακτική ή και αδύνατη.

Ο σκοπός του **FCA** αλγορίθμου είναι να επιλέξει τα υποσύνολα των ζωνών που διαχωρίζουν καλύτερα τα κέντρα ενός δοσμένου αριθμού τάξεων. Αυτό γίνεται δημιουργώντας όλους τους πιθανούς συνδυασμούς των **m** ζωνών, από το σύνολο των **N**, όπου **m** είναι ο επιθυμητός αριθμός των ζωνών στον οποίο θέλουμε να καταλήξουμε και **N** το σύνολο όλων των ζωνών.

Ο αριθμός των πιθανών συνδυασμών δίνεται απ' την εξίσωση :

$$\binom{N}{m} = \frac{N!}{(N-m)!m!}$$

Κάθε συνδυασμός αναφέρεται σαν ένα σύνολο. Ο πίνακας συμμεταβλητότητας και το μέσο για κάθε τάξη υπολογίζονται για κάθε σύνολο. Ανάμεσα σε όλα τα σύνολα αυτό με την μεγαλύτερη μέση απόσταση μεταξύ των κέντρων της τάξης επιλέγεται.

Το σύνολο αυτό αποτελεί την είσοδο στον ταξινομητή και όταν τελειώσει τον υπολογισμό τα ταξινομημένα pixels χρησιμοποιούνται για την επιλογή κάποιου άλλου πιθανού συνόλου.

Ο αλγόριθμος σταματά όταν το ίδιο σύνολο επιλέγεται συνέχεια ή όταν συμπληρωθεί ένας μέγιστος αριθμός επαναλήψεων.

### 3.5.3 Band Ratio

Η χρησιμοποίηση των λόγων των ζωνών αποτελεί άλλη μία μέθοδο για τη μείωση της διαστατικότητας.

Αυτή η μέθοδος εκμεταλλεύεται το γεγονός ότι κάποιες ζώνες είναι υψηλά συσχετιζόμενες. Δύο ζώνες λέγεται ότι είναι υψηλά συσχετιζόμενες όταν η πληροφορία που παρέχεται απ' τη μία είναι παρόμοια μ' αυτήν που παρέχεται απ' την άλλη.

Για παράδειγμα στον **Landsat MSS** (ζώνες 4-7) οι ζώνες 4 και 5 είναι υψηλά συσχετιζόμενες. Το δισδιάστατο ιστόγραμμα που χρησιμοποιεί τις δύο αυτές ζώνες μας δείχνει ότι οι τιμές **έντασης** (intensity) στη ζώνη 4 είναι ανάλογες αυτής στη ζώνη 5.

Ομοίως οι ζώνες 6 και 7 είναι επίσης συσχετιζόμενες. Θεωρούμε  $B_i$  την ένταση του pixel στη ζώνη  $i$ , όπου  $i=4$  ως 7. Μπορούμε να σχηματίσουμε δύο καινούριες ζώνες  $B'1$  και  $B'2$  ως εξής :

$$B'1 = \alpha_1 \times B_4/B_5 + b_1$$

όπου  $\alpha_1, \alpha_2, b_1, b_2$  είναι σταθερές.

$$B'2 = \alpha_2 \times B_6/B_7 + b_2$$

Η μέθοδος αυτή έχει πολύ σημαντική εφαρμογή στην τηλεπισκόπηση για τον παρακάτω λόγο :

Είναι γνωστό ότι η φασματική ανάκλαση κάποιων επιφανειών εξαρτάται από τη γωνία της ηλιακής έκθεσης και τη γωνία παρατήρησης .

Στην τηλεπισκόπηση εδάφους το τμήμα μιας πλαγιάς που εκτίθεται στο ηλιακό φως θα φαίνεται πιο έντονο την υπόλοιπη πλαγιά.

Αν θεωρήσουμε την επίδραση αυτού του φαινομένου σαν έναν πολλαπλασιασμό τότε το πρόβλημα λύνεται πολύ εύκολα με την τεχνική αυτή.

Η τεχνική αυτή επίσης απαιτεί πολύ λίγο χρόνο επεξεργασίας και συχνά είναι απ' τις πιο ακριβείς (Albert 2002, Käab 2002b, Paul 2002a,b).

# Κεφάλαιο 4<sup>ο</sup>

## Ταξινόμηση Υπερφασματικών Δεδομένων (Hyperspectral Imaging Classification)

### 4.1 Εισαγωγή

Η ταξινόμηση των υπερφασματικών δεδομένων είναι η διαδικασία ταυτοποίησης και καταχώρησης του κάθε pixel της εικόνας σε μία συγκεκριμένη τάξη σύμφωνα με κάποια στατιστικά χαρακτηριστικά των τιμών των εντάσεων του κάθε pixel .


Η ταξινόμηση των υπερφασματικών δεδομένων υπόκειται σαν διαδικασία στη ευρύτερη θεωρία της επιστήμης της **αναγνώρισης προτύπων** .

### 4.2 Αναγνώριση Προτύπων (Pattern Recognition)

Η αναγνώριση προτύπων είναι η επιστήμη που προσπαθεί να αναγνωρίσει με αυτόματο τρόπο χρήσιμες κανονικότητες σε πολύπλοκα και θορυβώδη περιβάλλοντα.

Πιο συγκεκριμένα, στόχος της αναγνώρισης προτύπων είναι η ταξινόμηση αντικειμένων σε ένα αριθμό κατηγοριών ή τάξεων .

Ένα γενικό σχήμα ενός συστήματος αναγνώρισης προτύπων φαίνεται στο παρακάτω διάγραμμα .



*Διαγρ . 7 Το γενικό διάγραμμα ενός συστήματος Αναγνώρισης Προτύπων*

Ένα φυσικό πρότυπο μετριέται απο ένα αισθητήριο όργανο .Ο αισθητήρας παρουσιάζει τις μετρήσεις σαν μία σειρά αριθμητικών τιμών .

Αυτό το σύνολο των αριθμών  $X=[x_1,x_2...x_n]$  , συνήθως αναπαρίσταται ως ένα διάνυσμα .

Έτσι και στην περίπτωση της υπερφασματικής απεικόνισης το κάθε pixel αναπαρίσταται ως ένα διάνυσμα με τιμές τις διαφορετικές τιμές εντάσεων σε κάθε φασματική ζώνη .

Το διάνυσμα αυτό στη συνέχεια τροφοδοτείται στον ταξινομητή ο οποίος αποφασίζει ποιό απ' τα πρότυπα αντιπροσωπεύει το κάθε διάνυσμα για κάθε pixel (Landgrebe 2003) .

### 4.3 Υπερφασματική ταξινόμηση

Όπως προαναφέραμε τα αντικείμενα προς ταξινόμηση περιγράφονται σε ένα χώρο χαρακτηριστικών .

Σ' αυτό το χώρο κάθε αντικείμενο δηλώνεται απο ένα διάνυσμα  $x = [x(1), x(2), \dots, x(N)]$  , όπου  $x_i, (i = 1 \text{ ως } N)$  δηλώνει ένα χαρακτηριστικό απο τα  $N$ .

Στη δική μας περίπτωση δεχόμαστε ως αντικείμενα προς ταξινόμηση τα ίδια τα pixels της εικόνας, σαν χαρακτηριστικά τις εντάσεις (**intensities**) των pixels στις διάφορες ζώνες μήκους κύματος, και σαν τελικό αποτέλεσμα την καταχώρηση του διανύσματος  $x$  σε μία τάξη  $\omega_j$  όπου  $j = 1 \text{ ως } K$  , με  $K$  τον αριθμό των συνολικών τάξεων.

Τυποποιώντας τον ορισμό του χώρου χαρακτηριστικών στην εφαρμογή μας μιλάμε για το  $N$ -διάστατο ιστόγραμμα της εικόνας όπου  $N$  είναι ο αριθμός των φασματικών ζωνών.

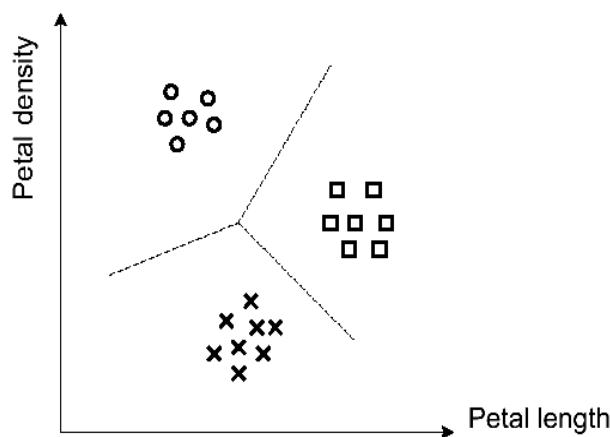
Το πρόβλημα της ταξινόμησης ανάγεται έτσι στην **κατάτμηση** του  $N$ -διάστατου χώρου χαρακτηριστικών σε περιοχές τάξεων, δηλαδή στην εύρεση μιας συνάρτησης απόφασης (**decision function**)  $f(x)$  τέτοια ώστε  $f(x) = \omega_j$  ,  $j = 1 \text{ ως } K$  .

Σίγουρα θα υπάρχουν κάποια σφάλματα στην ταξινόμηση. Η συνάρτηση αυτή θα πρέπει να ελαχιστοποιεί αυτά τα σφάλματα ταξινόμησης.

#### Ένα παράδειγμα :

Ξεκινώντας μπορούμε, σαν απλό παράδειγμα, να θεωρήσουμε ένα σύνολο δεδομένων απο τρία αντιπροσωπευτικά είδη λουλουδιών και τα αποτελέσματα να τα αναπαραστήσουμε στο χώρο χαρακτηριστικών, όπου σαν χαρακτηριστικά θεωρούμε την πυκνότητα και το μήκος των πετάλων. Η παρακάτω εικόνα μας δείχνει οτι τα λουλούδια διανέμονται σε τρεις καθαρά διαχωρισμένες μεταξύ τους ομάδες (**clusters**).

Δεδομένου ενός λουλουδιού θέλουμε να το ταξινομήσουμε σε μία απ' τις τρεις γνωστές τάξεις.



*Διαγρ . 8 Σ' αυτή την προσέγγιση ταξινόμησης μπορούμε να φανταστούμε κάποια όρια απόφασης (**decision boundaries**) στο χαρακτηριστικό πεδίο. Αυτά είναι οι κάθετοι διχοτόμοι ανάμεσα σε κάθε ζεύγος κέντρων. Κάθε είδος λουλουδιών περιορίζεται απο δύο όρια.*

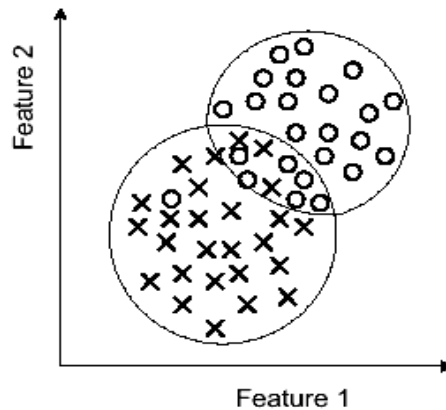
Σ' αυτή την περίπτωση τα όρια αυτά είναι καλά ορισμένα και δεν υπάρχει σφάλμα στην ταξινόμηση.

Η συνάρτηση απόφασης για το προηγούμενο παράδειγμα περιγράφεται παρακάτω :

Αρχικά βρίσκουμε τα κέντρα της κάθε ομάδας, το κάθε εκ' των οποίων είναι το κέντρο βάρους της κάθε ομάδας .

Για κάθε λουλούδι που είναι να ταξινομηθεί βρίσκουμε την απόσταση της θέσης του απ' το κέντρο της κάθε ομάδας, και η συνάρτηση απόφασης είναι η ανάθεση του κάθε λουλουδιού στην πλησιέστερη ομάδα.

Μία πιο ρεαλιστική κατάσταση όμως απεικονίζεται στο παρακάτω σχήμα στο οποίο βλέπουμε την επικάλυψη δύο διαφορετικών τάξεων σε μία περιοχή του χαρακτηριστικού πεδίου.



*Διαγρ . 9* Σάντό το παράδειγμα καμιά συνάρτηση απόφασης δε θα δώσει τέλεια αποτελέσματα οπότε και πρέπει να βασιστούμε σε στατιστικές με βάση ένα κριτήριο ελαχίστου σφάλματος κατά μέσο όρο .

#### 4.4 Μέθοδοι Ταξινόμησης

Τα pixels της υπερφασματικής εικόνας εξάγονται για να εκπαιδεύσουν τον ταξινομητή να αναγνωρίζει τα πρότυπα που θα τον βοηθήσουν στη διαφοροποίηση των τάξεων .

Βασιζόμενος σ' αυτά τα πρότυπα ο ταξινομητής δημιουργεί συναρτήσεις διαχωρισμού για την ανάθεση του κάθε pixel σε μία τάξη στο χώρο των χαρακτηριστικών (Landgrebe 2003) .

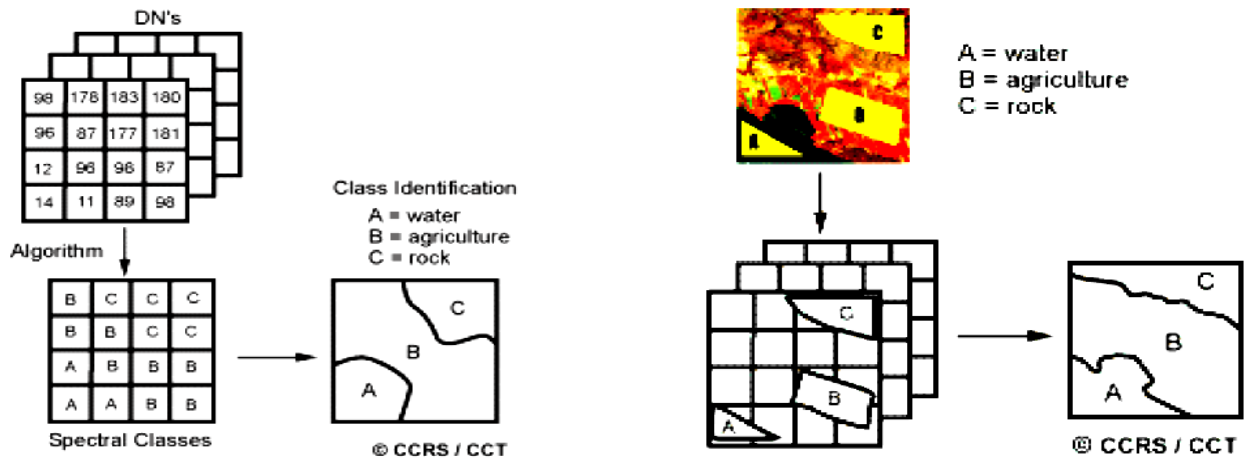
Δύο είναι κυρίως οι μέθοδοι που χρησιμοποιούμε στην ταξινόμηση εικόνας :

**Supervised** και **Unsupervised** ταξινόμηση.

Στη **Supervised ταξινόμηση**, υπάρχει μία εκ των προτέρων γνώση για τη χωρική κατανομή των τάξεων στην εικόνα . Έτσι μέσα απο μία διαδικασία συλλογής στοιχείων απο την απεικονιζόμενη περιοχή δημιουργούνται τα δείγματα εκπαίδευσης (**training sites**), τα φασματικά χαρακτηριστικά των οποίων χρησιμοποιούνται στην εκπαίδευση του αλγορίθμου για την ταξινόμηση των υπολοίπων pixels της εικόνας .

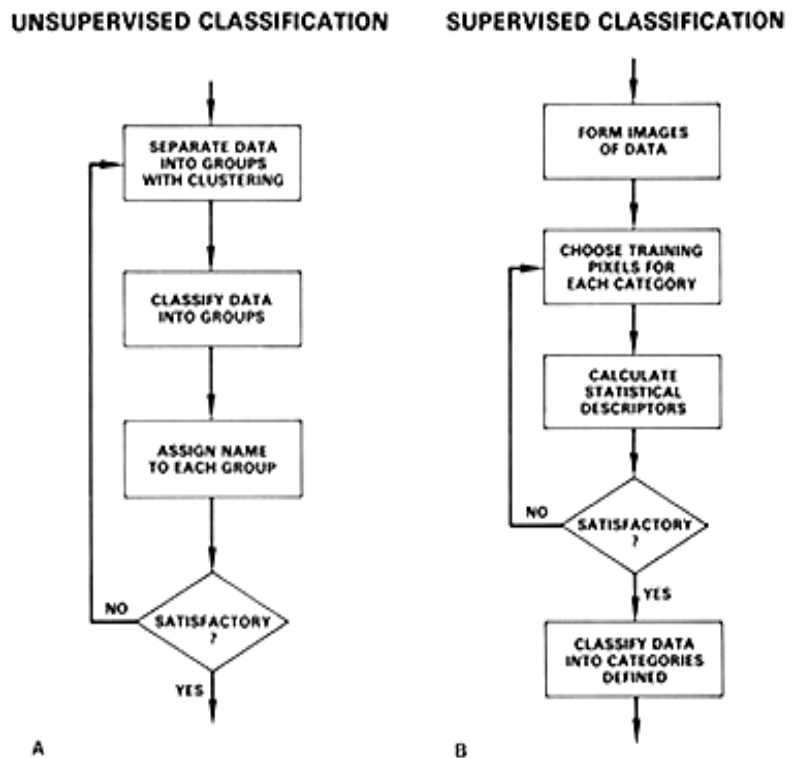
Έτσι κάθε pixel της εικόνας, συμπεριλαμβανομένων και των pixels των training sites , αποτιμάται και τοποθετείται στην τάξη στην οποία έχει την μεγαλύτερη πιθανότητα να ανήκει .

Στην **Unsupervised ταξινόμηση**, ο υπολογιστής ή ο αλγόριθμος ομαδοποιεί αυτόματα τα pixels που έχουν παρόμοια στατιστικά και φασματικά χαρακτηριστικά (μέσα ,τυπικές αποκλίσεις ,πίνακες συμμεταβλητότητας κ.α), σε μοναδικές ομάδες (**clusters**) σύμφωνα με στατιστικά καθορισμένα κριτήρια .



*Εικ . 22 Η λογική στην Unsupervised και Supervised ταξινόμηση αντίστοιχα*

*Διαγρ . 10  
Η λογική των βημάτων  
ταξινόμησης  
σε κάθε μια  
απ'της δύο μεθόδους*



Οι μέθοδοι ταξινόμησης μπορούν επίσης να διαχωριστούν και σε παραμετρικές και μη παραμετρικές .

Στην **παραμετρική ταξινόμηση** τα γνωρίσματα της κάθε τάξης ορίζονται από την **PDF** (συνάρτηση πυκνότητας πιθανότητας) της τάξης , οπότε οι παράμετροί της πρέπει να είναι γνωστοί ή να προσδιορίζονται στη διαδικασία του training.

Ένα παράδειγμα μίας PDF είναι η πολυδιάστατη **Gaussian** κατανομή με κάθε διάσταση να αντιστοιχεί σε μία φασματική ζώνη και με παραμέτρους το μέσο διάνυσμα (**mean vector**) και τον πίνακα συμμεταβλητότητας (**covariance matrix**), όπως στην περίπτωση του αλγορίθμου **Maximum Likelihood**.

Στην **μη παραμετρική ταξινόμηση** η **PDF** της κάθε τάξης δεν μας ενδιαφέρει.

## 4.5 Το στάδιο εκπαίδευσης (Training Stage)

Ενώ η ταξινόμηση των pixels πραγματοποιείται αυτόματα από κάποιον αλγόριθμο, το στάδιο της εκπαίδευσης πρέπει να γίνει προσεκτικά από τον διαχειριστή του συστήματος .

Η ποιότητα της εκπαίδευσης είναι ένας πολύ σημαντικός παράγοντας στην ταξινόμηση αφού ουσιαστικά καθορίζει την ποιότητα του τελικού αποτελέσματος .

Οι βασικοί στόχοι της διαδικασίας εκπαίδευσης είναι :

- να καθορίσει ποιές τάξεις μπορούν να αναγνωριστούν στην εικόνα ,
- να εξάγει τις στατιστικές παραμέτρους που περιγράφουν την κατανομή των ψηφιακών τιμών των εντάσεων σε κάθε τάξη .

Μία βασική προϋπόθεση της ταξινόμησης είναι η πληρότητα των δειγμάτων : πρέπει να υπάρχουν επαρκή δείγματα για όλες τις ανακλαστικές επιφάνειες της εικόνας .

Η κατάτμηση της εικόνας όμως σε τέτοιες ανακλαστικές επιφάνειες είναι γενικά διαφορετική απ' την ταυτοποίηση των περιοχών που μας ενδιαφέρουν στην εικόνα .

Μερικές φορές μία επιφάνεια αποτελείται από pixels τα οποία παρουσιάζουν μεγάλες διαφορές φασματικής ανάκλασης . Σ' αυτή την περίπτωση είναι απαραίτητη η περαιτέρω διαίρεση σε μικρότερες τάξεις οι οποίες θα μπορούν να αναγνωριστούν από το διαχειριστή.

Μία ακόμη προϋπόθεση που πρέπει να τηρούν τα δείγματα εκπαίδευσης είναι να είναι αντιπροσωπευτικά του πληθυσμού των τάξεων .

Αυτό συνεπάγεται ότι :

- Τα δείγματα εκπαίδευσης πρέπει να είναι αρκετά μεγάλα ώστε να περιέχουν έναν επαρκή αριθμό pixels για την εξαγωγή των στατιστικών παραμέτρων κατανομής των τάξεων .
- Τα δείγματα εκπαίδευσης πρέπει να είναι ομοιογενώς κατανομημένα ώστε να αναπαριστούν τη χωρική διακύμανση των τάξεων στην εικόνα .

Καταλήγουμε έτσι στην προϋπόθεση της ύπαρξης ενός ελαχίστου αριθμού δειγμάτων εκπαίδευσης ο οποίος εξαρτάται απ' τον αριθμό των φασματικών ζωνών που θα χρησιμοποιηθούν στην ταξινόμηση .

Γενικά ισχύει ότι όσο μεγαλύτερος είναι ο αριθμός των δειγμάτων σε μία τάξη τόσο καλύτερη περιγραφή των φασματικών χαρακτηριστικών της τάξης έχουμε .

Είναι παρ'όλα αυτά αδύνατο να δώσουμε ακριβείς ενδείξεις λόγω των διαφορετικών διαστάσεων και χωρικής κατανομής των επιφανειών ανάκλασης σε κάθε εικόνα .

Οι Lillesand και Kiefer (1987) προτείνουν ότι ο ελάχιστος αριθμός των δειγμάτων για ταξινόμηση σε  $n$  ζώνες , είναι απο  $10n$  για κάθε τάξη ως και  $100n$  .

Εναλλακτικά ο Richards (1993) προτείνει ότι τα δείγματα εκπαίδευσης πρέπει να καλύπτουν ένα ποσοστό ανάμεσα στο 1% και 3% της συνολικής επιφάνειας της εικόνας .

Πολλές φορές η εκπαίδευση χωρίζεται σε δύο σύνολα,ένα για τον υπολογισμό των γνωρισμάτων των τάξεων και ένα για την πιστοποίηση και αξιολόγηση της ακρίβειας της συνάρτησης απόφασης .

#### 4.6 Αποτίμηση της ακρίβειας (Accuracy Assessment)

Η ταξινόμηση μιας υπερφασματικής εικόνας οδηγεί στην ταυτοποίηση των pixels της εικόνας, με διάφορα διακριτά (φασματικά) υλικά.

Όταν όλα τα pixels έχουν ταξινομηθεί σε μία ή περισσότερες τάξεις (**classes**) μπορούμε να δημιουργήσουμε θεματικούς χάρτες (**thematic maps**) οι οποίοι ανάλογα με τη φύση της εφαρμογής μας μπορούν να χρησιμοποιηθούν για την αναγνώριση και ταυτοποίηση των αντικειμένων ή και την εξαγωγή στατιστικών πληροφοριών για τα αντικείμενα αυτά.

Πολλές φορές συσχετίζουμε τα pixel της ίδιας τάξης μεταξύ τους χωρίς πραγματικά να γνωρίζουμε τι ακριβώς είναι η συγκεκριμένη τάξη. Για να το γνωρίσουμε αυτό χρειαζόμαστε μια διαδικασία η οποία λέγεται **ground truthing** και πολλές φορές είναι εξαιρετικά δύσκολη λόγω της δυσκολίας πρόσβασης στη συγκεκριμένη περιοχή.

Όταν έχει ολοκληρωθεί η ταξινόμηση της εικόνας είναι πολύ σημαντικό να υπολογίσουμε την ακρίβεια των αποτελεσμάτων .

Η ακρίβεια της ταξινόμησης επαληθεύεται χρησιμοποιώντας ένα σύνολο δειγμάτων, προφανώς διαφορετικό απ' αυτό που χρησιμοποιήθηκε στην ταξινόμηση .

Η ταξινομημένη εικόνα συγκρίνεται με τα δείγματα επαλήθευσης και το αποτέλεσμα δίνεται απο έναν πίνακα ακρίβειας (**accuracy matrix**) (Congalton, 1991).

Οι στήλες του πίνακα αναπαριστούν τα δεδομένα επαλήθευσης ενώ οι γραμμές την ταξινομημένη εικόνα .

|                     | Water      | Woods | Bare soils | Crops | Row total |     |
|---------------------|------------|-------|------------|-------|-----------|-----|
| Classified<br>Image | Water      | 65    | 4          | 22    | 24        | 115 |
|                     | Woods      | 6     | 81         | 5     | 8         | 100 |
|                     | Bare soils | 0     | 11         | 85    | 19        | 115 |
|                     | Crops      | 4     | 7          | 3     | 90        | 104 |
|                     | Col. total | 75    | 103        | 115   | 141       | 434 |

← Tot. n. of pixels

**Average accuracy:**  $321/434 = 74\%$ ;  
**producer's accuracy**, for ex. crops:  $90/141 = 64\%$ ; **user's accuracy**, for ex. crops:  $90/104 = 87\%$

#### Πίνακας 5 . Παράδειγμα ενός πίνακα ακρίβειας

Γενικά στη διαδικασία αποτίμησης της ακρίβειας υπολογίζονται παράμετροι όπως η μέση ακρίβεια της ταξινόμησης (ο λόγος του συνολικού αριθμού των σωστά ταξινομημένων pixels και του συνολικού αριθμού των επαληθευμένων pixels) , η ακρίβεια της ταξινόμησης για κάθε τάξη κ.α .



Η διαδικασία αποτίμησης της ακρίβειας μας βοηθάει να επικεντρώσουμε σε ορισμένα κρίσιμα σημεία της διαδικασίας όπως είναι η φτωχή διαχωριστικότητα μεταξύ κάποιων τάξεων .

Σε μερικές περιπτώσεις μάλιστα όταν η ακρίβεια της ταυτοποίησης για κάποιες τάξεις είναι πολύ μικρή, είμαστε αναγκασμένοι να συγχωνεύσουμε τις τάξεις αυτές και να επαναλάβουμε τη συνολικά διαδικασία ταξινόμησης απ' το στάδιο της εκπαίδευσης .

#### **4.7 Βιβλιοθήκες Φασμάτων (Spectral Libraries)**

Οι βιβλιοθήκες φασμάτων (**spectral libraries**) είναι συλλογές φασμάτων ανάκλασης υλικών γνωστής σύνθεσης, τα οποία λαμβάνονται συνήθως στην ύπαιθρο ή στο εργαστήριο.

Πολλοί ερευνητές συλλέγουν φασματικές βιβλιοθήκες απο υλικά του πεδίου που τους ενδιαφέρει πριν προχωρήσουν στην ανάλυση πολυφασματικών ή υπερφασματικών απεικονίσεων του πεδίου αυτού.

Υπάρχουν διαθέσιμες πάρα πολλές φασματικές συλλογές υψηλής ποιότητας : Clark 1993, Grove 1992, Elvidge 1990, Korb 1996, Salisbury 1991a, Salisbury 1991b, Salisbury 1994.

Τα φάσματα απο τις βιβλιοθήκες αυτές μπορούν να χρησιμοποιηθούν σαν φάσματα αναφοράς σε supervised ταξινομήσεις .

Η σύγκριση διαφόρων μεθόδων συλλογής φασμάτων αναφοράς αναλύθηκε χρησιμοποιώντας φασματικές γωνίες και τα αποτελέσματα έδειξαν οτι πρέπει να δώσουμε ιδιαίτερη προσοχή στις διαφορετικές μεθόδους συλλογής των φασμάτων .

#### **4.8 Μέθοδοι Συλλογής Φασμάτων Αναφοράς**

Η ποιότητα των φασμάτων αναφοράς είναι ένας σημαντικός παράγοντας ο οποίος επηρεάζει πολύ τα αποτελέσματα της ταξινόμησης και γι' αυτό το λόγο υπάρχουν πολλοί τρόποι για τη συλλογή τους .

Στην περίπτωση που μοναδικά και αγνά pixels χρησιμοποιούνται κατ' ευθείαν σαν φάσματα αναφοράς, η ανάκλαση των pixels πρέπει να εξαχθεί μόνο απο υλικά τα οποία καθορίζονται απο το pixel. Αν υπάρχουν διαφορές ανάμεσα στα χαρακτηριστικά ανάκλασης μέσα σε μία τάξη τότε θα χρειαστούμε κι άλλα φάσματα αναφοράς.


Πολλοί τρόποι υπάρχουν και για τον υπολογισμό των φασμάτων αναφοράς και απ' τις περιοχές εκπαίδευσης είτε υπολογίζοντας τη μέση τιμή των τιμών του pixel απο έναν αριθμό καναλιών, είτε επιλέγοντας το μέσο των τιμών του pixel ή τέλος επιλέγοντας την πιο συχνά εμφανιζόμενη τιμή του pixel σαν αναφορά.

##### **Ένα παράδειγμα :**

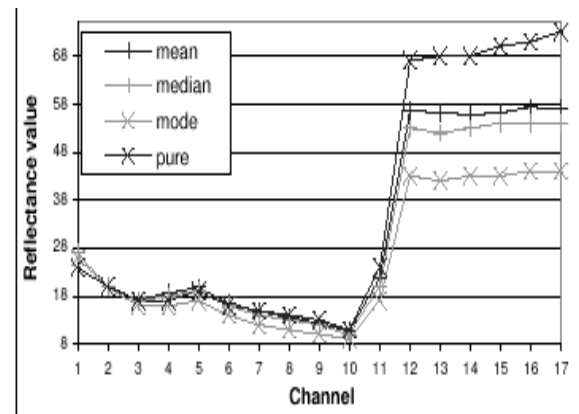
Για να δούμε την εξαιρετική σημασία του τρόπου επιλογής των φασμάτων αναφοράς επιλέγουμε μία μικρή δοκιμαστική περιοχή με 100 pixels για πιο λεπτομερή ανάλυση.

Τα φάσματα αναφοράς έχουν εξαχθεί απ' αυτήν την περιοχή η οποία απεικονίζει ένα πυκνό δάσος και περιλαμβάνει έλατα, σκιές και βράχους .

**Εικ . 23** 10 x 10 pixel περιοχή της υπερφασματικής εικόνας. Τα έντονα pixels είναι οι φωτεινές κορυφές των δέντρων και τα σκούρα σκιές ανάμεσα στα έλατα.



**Διαγρ . 11** Τα φάσματα αναφοράς που έχουν υπολογιστεί με τη μέση τιμή των τιμών των pixels, το μέσο των τιμών και την πιο συχνά εμφανιζόμενη τιμή για 17 κανάλια, καθώς και το φάσμα από ένα αγνό pixel έλατου.




Institute of Photogrammetry and Remote Sensing,  
Helsinki University of Technology

Η σύγκριση των μεθόδων συλλογής των φασμάτων αναφοράς έχει αναλυθεί χρησιμοποιώντας φασματικές γωνίες και δημιουργώντας εικόνες αναπαράστασης των φασματικών γωνιών. Έτσι στην παρακάτω εικόνα τα λαμπερά pixels μας δείχνουν μικρές τιμές φασματικών γωνιών και τα πιο σκούρα μεγαλύτερες.

Οι μικρές φασματικές γωνίες μας δείχνουν ότι το φάσμα αναφοράς επιτυγχάνει καλύτερη περιγραφή της περιοχής οπότε όσο περισσότερα είναι τα ανοιχτά pixels στην εικόνα τόσο καλύτερη επιλογή αποτελεί το συγκεκριμένο φάσμα αναφοράς για την περιγραφή της περιοχής.

**Εικ . 24** Οι φασματικές γωνίες μεταξύ των pixels της περιοχής που επιλέξαμε και των φασμάτων αναφοράς.



Institute of Photogrammetry and Remote Sensing,  
Helsinki University of Technology

Παρατηρούμε ότι χρησιμοποιώντας τη μέση τιμή έχουμε καλύτερα αποτελέσματα στον υπολογισμό του φάσματος αναφοράς απ' την επιλογή του μέσου των τιμών των pixels.

Συγκρίνοντας την εικόνα της δοκιμαστικής περιοχής με τις εικόνες των φασματικών γωνιών βλέπουμε ότι τα φάσματα αναφοράς που εξήχθησαν με τις μεθόδους της μέσης τιμής και του μέσου δεν μπόρεσαν να ορίσουν τα σκοτεινά pixels στη δοκιμαστική περιοχή.

Οι φασματικές γωνίες του φάσματος αναφοράς με τη mode μέθοδο ήταν μεγάλες και συγκεκριμένα η μέθοδος αυτή έδωσε κακά αποτελέσματα στην περίπτωση των pixels των φωτεινών κορυφών σε αντίθεση με τη μέθοδο του pure pixel.

Όλα τα αποτελέσματα όμως ήταν φτωχά στον ορισμό των σκοτεινών pixels των σκιών στην εικόνα.

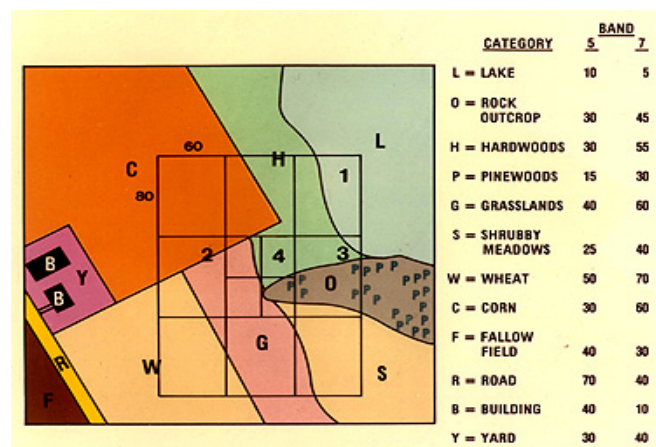
#### 4.9 Φασματικός Διαχωρισμός (Spectral unmixing)

Μία απ' τις μεγαλύτερες προκλήσεις σε όλες τις εφαρμογές της υπερφασματικής απεικόνισης είναι η διαδικασία του φασματικού διαχωρισμού (**spectral unmixing**) κατά την οποία το αναμεμιγμένο pixel (**mixed pixel**) μπορεί να ανακατασκευαστεί από γνωστά φάσματα στην εικόνα ή να διασπαστεί στα μεμονωμένα φάσματα ανάκλασης των συστατικών του (**endmembers**).

Η ύπαρξη των mixed pixels οφείλεται στο ότι ορισμένες περιοχές οι οποίες απαρτίζονται από διαφορετικά χαρακτηριστικά ή τάξεις μπορεί να είναι (γεωμετρικά) μικρότερες απ' τη χωρική ανάλυση του αισθητήρα.

Κοιτώντας τον παρακάτω υποθετικό χάρτη παρατηρούμε ότι σε κάποια pixels εμπεριέχονται δύο ή και περισσότερες τάξεις. Το εξαγώμενο φάσμα σ' αυτή την περίπτωση θα είναι μια σύνθεση των φασμάτων της κάθε τάξης καθιστώντας έτσι την ταυτοποίηση τους εξαιρετικά δύσκολη.

Υπάρχουν κάποιες μαθηματικές μέθοδοι για την αντιμετώπιση αυτού του προβλήματος αλλά στις περισσότερες των περιπτώσεων υπάρχει μια στατιστική αβεβαιότητα. Μία σχετική βελτίωση είναι η αύξηση της χωρικής ανάλυσης του αισθητήρα (μείωση μεγέθους pixel), όπως στο μεσαίο τετράγωνο της παρακάτω εικόνας, αλλά έτσι απλά μειώνεται ο αριθμός των mixed pixels.



**Εικ . 25** Ο κανόνας για τη βελτιστοποίηση της ταξινόμησης είναι να αναζητήσουμε μία ανάλυση η οποία θα προσεγγίζει το μέγεθος της μικρότερης τάξης που θέλουμε να ταυτοποιήσουμε.

Η χωρική ανάλυση του αισθητήρα όμως πολλές φορές είναι περιορισμένη, έτσι είναι απαραίτητο ή σύνθετη φασματική υπογραφή του κάθε mixed pixel να διασπαστεί για να προσδιοριστούν όλα τα μεμονωμένα υλικά που τη συνθέτουν.

Είναι πιθανό η φασματική υπογραφή ενός μόνο υλικού που περιλαμβάνεται στο pixel να κυριαρχεί στα φασματικά χαρακτηριστικά του pixel.

Γενικά όμως είμαστε υποχρεωμένοι να πραγματοποιούμε μια unmixing analysis.

Μ'αυτόν τον όρο εννοούμε τον εντοπισμό και την αναγνώριση ενός ή και περισσότερων υλικών σε ένα pixel.

Το φάσμα του κάθε pixel τότε μπορεί να αναπαρασταθεί σαν ένα σταθμισμένο άθροισμα των φασματικών υπογραφών των endmembers.

Κάποιοι αλγόριθμοι που έχουν αναπτυχθεί γι'αυτήν τη δουλειά είναι οι : **Independent Component Analysis (ICA)**, **Vertex Component Analysis (VCA)** και ο **Filter Vector Algorithm (FVA)**, (Palmadesso, et al., 1995 and Bowles, et al., 1995) .

Αυτοί οι αλγόριθμοι χρησιμοποιήθηκαν για να βρεθούν προσεγγιστικά τα endmembers όταν δεν υπήρχε καμία γνώση για τα υλικά που συντελούσαν στο φασματικό μείγμα.

Για να είναι αποτελεσματικοί αυτοί οι αλγόριθμοι είναι απαραίτητη η πρόσβασή τους σε φασματικές βιβλιοθήκες οι οποίες θα περιέχουν επαρκή και κατάλληλα δείγματα φασμάτων ανάκλασης .

# Κεφάλαιο 5<sup>ο</sup>

## Αλγόριθμοι Ταξινόμησης

### 5.1 Εισαγωγή

Η διαδικασία της φασματικής ταξινόμησης υπόκειται στο πεδίο της αναγνώρισης προτύπων (**Pattern Recognition**) και με τέτοιους αλγόριθμους αντιστοιχίζουμε τα αντικείμενα σε προκαθορισμένες κατηγορίες ή τάξεις.

Διάφορες τεχνικές ταξινόμησης έχουν προταθεί όπως : ελάχιστης απόστασης (**minimum distance** : **Euclidean**, **Fisher Linear Discriminant**, **Mahalanobis**, κλπ.), μέγιστης πιθανότητας (**maximum likelihood**) και ασαφούς λογικής όπως **Linear Spectral Unmixing** , **Mixed Tuned Matched Filtering** κ.α .


Τα υπερφασματικά δεδομένα μπορούν να ταξινομηθούν και με συμβατικούς αλγόριθμους οι οποίοι συχνά χρησιμοποιούνται στην πολυφασματική ταξινόμηση.

Σ'αυτήν την περίπτωση πρέπει να δώσουμε ιδιαίτερη προσοχή στα ζώνες που θα επιλέξουμε για την εξαγωγή της πληροφορίας.

Μόνο κάποια απ'τα κανάλια θα επιλεγθούν απ'τα εκατοντάδες της υπερφασματικής απεικόνισης .

Υπάρχουν όμως και αρκετοί αλγόριθμοι οι οποίοι αναπτύχθηκαν για την ταξινόμηση υπερφασματικών δεδομένων και είναι πιο αποτελεσματικοί σε υπερδιάστατο χώρο .

Σ'αυτή την περίπτωση τα φάσματα αναφοράς που συλλέγονται (**training data**) παίζουν εξέχοντα ρόλο στην ταξινόμηση.



**Εικ . 26** Δύο θεματικοί χάρτες της ίδιας περιοχής , ταξινομημένης με συμβατικούς και υπερφασματικούς αλγόριθμους αντίστοιχα .

Στη συνέχεια θα δούμε αναλυτικά κάποιους απ'τους βασικότερους αλγόριθμους ταξινόμησης δεδομένων υπερφασματικής απεικόνισης .

## 5.2 Parallelepiped Classification

Μία απ' της πιο απλές supervised μεθόδους ταξινόμησης είναι η τεχνική του παραλληλεπίπεδου (**parallelepiped**). Ένα παραλληλεπίπεδο είναι ένα **n-διάστατο** σχήμα με επίπεδες επιφάνειες.

Ο αλγόριθμος του παραλληλεπίπεδου ορίζει κάθε **training set** ως ένα **n-διάστατο παραλληλεπίπεδο**, όπου **n** είναι ο αριθμός των φασματικών ζωνών στην εικόνα .

Οι διαστάσεις του κάθε παραλληλεπίπεδου ορίζονται με βάση ένα όριο που θέτει ο διαχειριστής και την τυπική απόκλιση απ' το μέσο της κάθε τάξης.

Τα pixels τα οποία βρίσκονται σε μία μοναδική τάξη παραλληλεπίπεδου ταξινομούνται σ' αυτήν την τάξη.

Τα pixels τα οποία δεν συμπίπτουν με καμία τάξη παραλληλεπίπεδου ή ανήκουν σε περιοχές στις οποίες υπάρχουν επικαλυπτόμενα παραλληλεπίπεδα δεν ταξινομούνται σε καμία τάξη.

Οι ακόλουθες διαδικασίες χρησιμοποιούνται για τον προσδιορισμό των ορίων :

- Παρουσίασε μία ζώνη δεδομένων
- Εφάρμοσε μία συνάρτηση μετασχηματισμού πυκνότητας για την ανάδειξη των εντάσεων **I<sub>min</sub>** ως **I<sub>max</sub>** των pixels ώστε να απομονώσουμε την επιθυμητή τάξη.
- Επανάλαβε τα παραπάνω βήματα για όλες τις επιθυμητές τάξεις
- Επανάλαβε όλα τα παραπάνω βήματα για όλες τις υπόλοιπες ζώνες.

Η συνάρτηση απόφασης μπορεί τώρα να εφαρμοστεί πολύ εύκολα αφού αποτελείται μόνο απ' τον έλεγχο του κάθε δείγματος στα παραπάνω όρια.

Πιο αναλυτικά :

$$\mu_{ck} - \sigma_{ck} \leq BV_{ijk} \leq \mu_{ck} + \sigma_{ck}$$

$$L_{ck} \leq BV_{ijk} \leq H_{ck}$$

Όπου **BV<sub>ijk</sub>** και **BV<sub>ijl</sub>** , οι τιμές των εντάσεων του pixel **ij** , στη ζώνη **k** , **μ<sub>ck</sub>** το μέσο των τιμών όλων των pixels της τάξης **c** στη ζώνη **k** και **σ<sub>ck</sub>** η διακύμανση των τιμών των pixels της τάξης **c** στη ζώνη **k** .

Παρά την απλότητα και αποτελεσματικότητα που φαίνεται να έχει αυτός ο αλγόριθμος παρουσιάζει αρκετές αδυναμίες. Αν επιλεγθεί ένα μικρό όριο τα παραλληλεπίπεδα θα είναι πολύ μικρά και πολλά pixels δε θα ταξινομηθούν.

Αν απ' την άλλη επιλέξουμε μεγάλο όριο πολλές τάξεις παραλληλεπίπεδων θα επικαλύπτονται οπότε πάλι θα έχουμε μη ταξινομημένα pixels.

Αυτό είναι ένα πρόβλημα ειδικά όταν έχουμε να κάνουμε με υψηλά συσχετιζόμενα σύνολα δεδομένων (Richards και Jia, 1986).

Επίσης απαιτεί μεγάλο χρόνο αλληλεπίδρασης με το διαχειριστή ειδικά όταν ο αριθμός των φασματικών ζωνών αυξάνεται.

Η παραλληλεπίπεδη ταξινόμηση είναι **supervised** και **μη παραμετρική** ταξινόμηση αφού οι τιμές των **I<sub>min</sub>** και **I<sub>max</sub>** προσδιορίζονται απ'το διαχειριστή και η συνάρτηση απόφασης βασίζεται στα όρια απόφασης και όχι στις **PDF** των τάξεων.

Παρ'όλα αυτά μπορεί να θεωρηθεί παραμετρική αν θεωρήσουμε την PDF της κάθε τάξης σαν μια πολυδιάστατη ομοιόμορφη κατανομή ανάμεσα στα **I<sub>min</sub>** και **I<sub>max</sub>**, τα οποία θα θεωρήσουμε και σαν παραμέτρους .

### 5.3 Nearest Neighbour

Η συνάρτηση απόφασης σε έναν **Nearest Neighbour** ταξινομητή είναι η ανάθεση του δείγματος προς ταξινόμηση στην πλησιέσταιρη ομάδα (**cluster**) οπότε χρειαζόμαστε ένα κριτήριο πλησιότητας.

Υπάρχουν τρεις παραλλαγές του ταξινομητή ανάλογα με το κριτήριο πλησιότητας που χρησιμοποιούμε.

1. Ταξινόμησε το δείγμα στην τάξη της οποίας το κέντρο ομάδας είναι πλησιέσταιρο στο διάνυσμα του δείγματος. Τα κέντρα των ομάδων λαμβάνονται στο στάδιο της εκπαίδευσης. Αυτή η συνάρτηση απόφασης είναι πολύ εύκολο να υλοποιηθεί και χρησιμοποιείται σε πολλούς ταξινομητές του εμπορίου.
2. Ταξινόμησε το δείγμα στην τάξη του πλησιέσταιρου δείγματος που λήφθηκε κατά την εκπαίδευση. Σ'αυτήν την περίπτωση δεν απαιτούνται γνωρίσματα για κάθε τάξη. Η υλοποίηση είναι αρκετά δύσκολη αφού πρέπει να υπολογιστεί η απόσταση του δοσμένου δείγματος με όλα τα δείγματα σε όλες τις τάξεις.
3. Αναγνώρισε τα **k** δείγματα που λήφθηκαν κατά την εκπαίδευση και είναι πλησιέσταιρα στο δοσμένο δείγμα . Οπου **k** είναι ένας προκαθορισμένος αριθμός . Στη συνέχεια εφαρμόσε τον κανόνα της πλειοψηφίας για την ταξινόμηση του δοσμένου δείγματος . Αυτή η παραλλαγή ονομάζεται **k-nearest neighbour** και παρουσιάζει την ίδια δυσκολία με τη δεύτερη αφού στην ουσία είναι η ίδια με **k=1**.

Λόγω του ότι η πρώτη παραλλαγή είναι αυτή που χρησιμοποιείται περισσότερο, η **Nearest Neighbouring Classification** στην βιβλιογραφία παραπέμπει σ'αυτήν την παραλλαγή εκτός αν επισημανθεί κάτι διαφορετικό.

Η ταξινόμηση αυτή είναι **μη παραμετρική** αφού η συνάρτηση απόφασης βασίζεται στη μέτρηση της απόστασης και όχι στις **PDF** των τάξεων.

Επίσης μπορεί να είναι **Supervised** αν ο διαχειριστής αναγνωρίζει τα δείγματα για εκπαίδευση, ή **Unsupervised** αν χρησιμοποιούμε ένα αυτόματο αλγόριθμο ομαδοποίησης.

Μπορεί να αποδειχτεί ότι η **Nearest Neighbour** συνάρτηση απόφασης είναι δύο φορές χειρότερη απ'τη **Maximum Likelihood** όσον αφορά στην ακρίβεια της ταξινόμησης.

Τα αποτελέσματα της ταξινόμησης επηρεάζονται πολύ απ'τη βαθμολόγηση των αξόνων στο χαρακτηριστικό πεδίο. Μία κοινή πρακτική είναι να εφαρμόσουμε μία επέκταση δυναμικού εύρους στις ζώνες πριν την ταξινόμηση, ώστε τα δυναμικά εύρη των εντάσεων σε κάθε ζώνη να γίνουν ίσα.

Μία άλλη μέθοδος είναι να κανονικοποιήσουμε την απόσταση στην τυπική απόκλιση.

## 5.4 Euclidean Distance

Στους περισσότερους αλγόριθμους ταξινόμησης κάθε pixel του τελικού θεματικού χάρτη πρέπει να είναι ταξινομημένο σε έναν αριθμό C τάξεων.

Ο αλγόριθμος **Euclidean Distance** παίρνει C αρχικά σημεία στην εικόνα. Σ' αυτήν την περίπτωση τα σημεία αντιπροσωπεύουν τα υλικά που θέλουμε να αναγνωρίσουμε.

Υπολογίζεται η απόσταση μεταξύ κάθε διανύσματος pixel στην εικόνα και των C διανυσμάτων των σημείων που επιλέξαμε, χρησιμοποιώντας την **Ευκλείδεια εξίσωση** :

$$\text{Όπου } X \text{ είναι το διάνυσμα του pixel} \quad g_i(x) = (X - M_i)^T (X - M_i) \\ \text{και } M_i \text{ είναι το μέσο διάνυσμα της τάξης } i .$$

Πιο αναλυτικά :

$$Dist = \sqrt{(BV_{ijk} - \mu_{ck})^2 + (BV_{ijl} - \mu_{cl})^2}$$

Όπου  $BV_{ijk}$  και  $BV_{ijl}$ , οι τιμές των εντάσεων του pixel  $ij$ , στις ζώνες  $k$  και  $l$  αντίστοιχα, και  $\mu_{ck}$  και  $\mu_{cl}$  τα μέσα των τιμών όλων των pixels της τάξης  $c$ , στις ζώνες  $k$  και  $l$  αντίστοιχα.

Κάθε διάνυσμα pixel καταχωρείται σαν μέλος του πλησιέστου σημείου C.

Όταν όλα τα pixels στην εικόνα έχουν καταχωρηθεί σαν μέλη ενός των C συνόλων κάθε σύνολο απ' τα C υπολογίζει το δικό του νέο σημείο ή μέσο. Με τα νέα σημεία τώρα επαναλαμβάνεται η όλη διαδικασία με αποτέλεσμα τη νέα ταξινόμηση των διανυσμάτων σαν μέλη ενός απ' τα C.

Η διαδικασία επαναλαμβάνεται μέχρι να μην αλλάζει κανένα pixel απ' τη μια τάξη στην άλλη, ή ακολουθώντας έναν αριθμό επαναλήψεων.

Συνήθως για ικανοποιητικά αποτελέσματα απαιτούνται απο πέντε επαναλήψεις και πάνω.

Τα βήματα του Euclidean Distance Classifier :

- **Get C initial means**
- **For each iteration**
  - **Calculates pixel distances and assign membership**
  - **Calculates new means based on the class members**
- **Returns a classification vector**

Ο αλγόριθμος αυτός είναι ευρέως διαδεδομένος αλλά έχει ένα ελάττωμα. Υποθέτει ότι όλα τα σημεία απέχουν την ίδια απόσταση απ' το κέντρο τους οπότε η ταξινομημένη περιοχή θα είναι πάντα κυκλική. Βασικά υποθέτει τον πίνακα συμμεταβλητότητας σαν μοναδιαίο πίνακα.

Αν η κατανομή των δεδομένων σε κάθε τάξη δεν βασίζεται σε ισαπέχοντα σημεία η ταξινόμηση μπορεί να αποτύχει.



## 5.5 Maximum Likelihood

Ο **Maximum Likelihood** ταξιμομητής βασίζεται σε τεχνικές στατιστικής ανάλυσης οπότε και απαιτείται η γνώση των παρακάτω βασικών στοιχείων της θεωρίας πιθανοτήτων.

**Δεσμευμένη (ή υπο συνθήκη) πιθανότητα :**

Μία δεσμευμένη πιθανότητα δηλώνεται ως  $p(\mathbf{A}|\mathbf{B})$  και είναι η πιθανότητα να συμβεί το ενδεχόμενο A δεδομένου ότι έχει ήδη συμβεί το ενδεχόμενο B.

**Θεώρημα του Bayes :**

Αν  $p(\mathbf{A},\mathbf{B})$  είναι η πιθανότητα και τα δύο ενδεχόμενα A και B να συμβούν, το θεώρημα του Bayes μας λέει ότι :

$$P(\mathbf{A},\mathbf{B})=p(\mathbf{A}|\mathbf{B})p(\mathbf{B})=p(\mathbf{B}|\mathbf{A})p(\mathbf{A})$$

ή αλλιώς

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

**Συνάρτηση Πυκνότητας Πιθανότητας :**

Αν x μία τυχαία μεταβλητή με Gaussian κατανομή,  $\mu$  η μέση τιμή του x και  $\sigma$  η τυπική του απόκλιση (standard deviation) τότε η συνάρτηση πυκνότητας πιθανότητας  $p(x)$  είναι :

$$p(x) = \frac{1}{\sqrt{2\pi} \sigma} \exp \left[ -\frac{(x - \mu)^2}{2 \sigma^2} \right]$$

**Gaussian κατανομή πολλαπλών τυχαίων μεταβλητών (Multi-Variate Gaussian Distribution) :**

Έστω  $\chi$  μία N-διάστατη τυχαία μεταβλητή με Gaussian κατανομή πολλαπλών τυχαίων μεταβλητών,  $\mu$  το μέσο διάνυσμα του  $\chi$  και C η συμμεταβλητότητα.

Για παράδειγμα μία ομάδα pixels μιας εικόνας που λαμβάνονται σε N φασματικές ζώνες έχουν Gaussian κατανομή πολλαπλών μεταβλητών.

Το στοιχείο της i γραμμής και j στήλης του πίνακα συμμεταβλητότητας (covariance matrix) είναι η συμμεταβλητότητα (covariance) μεταξύ της i και j φασματικής ζώνης.


Η συνάρτηση πυκνότητας πιθανότητας  $p(\mathbf{x})$  είναι :

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{N/2} |\mathbf{C}|^{1/2}} \exp \left[ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \mathbf{C}^{-1}(\mathbf{x} - \boldsymbol{\mu}) \right]$$


Ο Maximum Likelihood είναι ένας ταξινομητής ο οποίος χρησιμοποιεί στατιστικές προσεγγίσεις για να ελαχιστοποιήσει το σφάλμα ταξινόμησης.

Η ταξινόμηση είναι **παραμετρική** αφού προϋποθέτει ότι τα διανύσματα των pixels σε κάθε τάξη, για κάθε φασματική ζώνη ακολουθούν κανονική κατανομή (Gaussian).

Οι PDFs είναι σημαντικές σ' αυτή την στατιστική προσέγγιση και η ταξινόμηση μπορεί να είναι και **Supervised** και **Unsupervised** ανάλογα με τη μέθοδο εκπαίδευσης που ακολουθήθηκε.



*Διαγρ. 12 Κατανομή της συχνότητας δεδομένων για μία τάξη  $\omega$ , σε μία ζώνη  $k$*



*Διαγρ. 13 Κατανομή της συχνότητας δεδομένων για μία τάξη  $\omega$ , σε μία ζώνη  $k$ , στρογγυλοποιημένη από τη συνάρτηση πυκνότητας πιθανότητας*

Αν  $\chi$  είναι το μετρούμενο διάνυσμα και  $\omega_i$  μία τάξη, η συνάρτηση απόφασης του Maximum Likelihood Classifier είναι :

**αν  $p(x|\omega_i)p(\omega_i) > p(x|\omega_j)p(\omega_j)$  για κάθε  $j, i \neq j$  τότε ανάθεσε το  $\chi$  στην  $\omega_i$**

Ουσιαστικά υπολογίζει την πιθανότητα για κάθε pixel να ανήκει σε κάθε μία απ' τις τάξεις και αναθέτει το pixel στην τάξη για την οποία έχει τη μεγαλύτερη πιθανότητα να ανήκει.

Οπότε πρέπει να υπολογίσουμε τις τιμές των  $p(x|\omega_i)p(\omega_i)$  για όλες τις τάξεις  $\omega_i$  και να επιλέξουμε τη μέγιστη τιμή. Οι δεσμευμένες πιθανότητες  $p(x|\omega_i)$  λαμβάνονται κατά την εκπαίδευση.

Η πιθανότητα  $p(\omega_j)$  είναι άγνωστη και θα δούμε στη συνέχεια πως την υπολογίζουμε.

Αφού το  $\chi$  είναι γνωστό μπορούμε να υπολογίσουμε τις τιμές των  $p(\omega_i|x)$  για κάθε τάξη  $\omega_i$  και να επιλέξουμε τη μέγιστη τιμή.

Αυτό είναι λογικό αφού η πιθανότητα  $p(\omega_i|x)$  είναι η πιθανότητα του  $x$  να ανήκει στην τάξη  $\omega_i$  δοσμένης της μέτρησης του  $x$ .

Στην ουσία αυτό είναι ίσο με την παραπάνω συνάρτηση απόφασης και μπορεί να αποδειχτεί με το θεώρημα του Bayes.

$$p(\omega_i|x) = p(x|\omega_i)p(\omega_i) / p(x)$$

Το αριστερό μέλος μεγιστοποιείται όταν μεγιστοποιείται ο αριθμητής του δεξιού μέλους αφού η πιθανότητα  $p(\mathbf{x})$  είναι σταθερή σε δοσμένη μέτρηση.

Για να αξιοποιήσουμε την παραπάνω συνάρτηση απόφασης πρέπει να γνωρίζουμε τη δεσμευμένη πιθανότητα  $p(\mathbf{x}|\omega_i)$  για κάθε τάξη  $\omega_i$ .

Η συναρτησιακή μορφή της δεσμευμένης πιθανότητας είναι στην αρχή άγνωστη για μας οπότε πρέπει να αρχίσουμε με μία υπόθεση. Η πιο λογική υπόθεση που μπορούμε να κάνουμε είναι αυτή της **Gaussian** κατανομής πολλαπλών τυχαίων μεταβλητών, οπότε στο  $N$ -διάστατο χαρακτηριστικό πεδίο η δεσμευμένη πιθανότητα είναι :

$$p(\mathbf{x}|\omega_i) = \frac{1}{(2\pi)^{N/2} |\mathbf{C}_i|^{1/2}} \exp \left[ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_i)^T \mathbf{C}_i^{-1}(\mathbf{x} - \boldsymbol{\mu}_i) \right]$$

όπου  $\mathbf{x}^T$  είναι ο ανάστροφος του  $\mathbf{x}$  ,  $\boldsymbol{\mu}_i$  είναι το μέσο διάνυσμα ,  $\mathbf{C}_i$  είναι ο πίνακας συμμεταβλητότητας ,  $\mathbf{C}_i^{-1}$  είναι ο αντίστροφος του  $\mathbf{C}_i$  και  $|\mathbf{C}_i|$  είναι η ορίζουσα του  $\mathbf{C}_i$  .

Οι διαστάσεις του μέσου διανύσματος είναι  $N \times 1$  και του πίνακα συμμεταβλητότητας  $N \times N$ .

Κάθε στοιχείο του μέσου διανύσματος είναι η μέση τιμή της έντασης (intensity) σε μία ζώνη .

Κάθε στοιχείο στον πίνακα συμμεταβλητότητας γραμμής  $\mathbf{j}$  και στήλης  $\mathbf{k}$  είναι η συμμεταβλητότητα μεταξύ των εντάσεων των ζωνών  $\mathbf{j}$  και  $\mathbf{k}$  .

Τα αποτελέσματα της ταξινόμησης δεν επηρεάζονται απ'τη βαθμολόγηση των αξόνων στο χαρακτηριστικό πεδίο.

Το μέσο και η συμμεταβλητότητα πρέπει να ξαναυπολογιστούν για κάθε τάξη.

Ο αλγόριθμος σταματάει όταν δεν υπάρχει ουσιαστική αλλαγή μετά απο κάθε υπολογισμό ή μετά απο καθορισμένο αριθμό επαναλήψεων.

Χωρίς να συμπεριλάβουμε την πληροφορία για τις πιθανότητες  $p(\omega_i)$  για κάθε τάξη ,που όμως είπαμε είναι άγνωστες , η συνάρτηση απόφασης γίνεται :

Αποφάσισε αν το άγνωστο διάνυσμα  $\mathbf{X}$  ανήκει στην τάξη  $\mathbf{i}$  αν και μόνο αν  $p(\mathbf{i}) \geq p(\mathbf{j})$  , για κάθε  $\mathbf{i}$  και  $\mathbf{j}$  , απο τις  $\mathbf{1}, \mathbf{2}, \dots, \mathbf{m}$  πιθανές τάξεις , και :

$$p_i = \frac{1}{2} \log_e |V_i| - \left[ \frac{1}{2} (\mathbf{X} - M_i)^T V_i^{-1} (\mathbf{X} - M_i) \right]$$

## 5.6 Bayes Classifier

Ο Bayes ταξινομητής είναι παρόμοιος με τον Maximum Likelihood, αλλά επιπλέον λαμβάνει υπόψιν του το κόστος και της σωστής και της λάθος ταξινόμησης.

Τυποποιώντας την Bayes ταξινόμηση έστω  $L_{ij}$  είναι η απώλεια της ταξινόμησης ενός δείγματος στην τάξη  $\omega_j$  ενώ ανήκει στην τάξη  $\omega_i$ . Τότε η απώλεια  $L_{ii}$  είναι το κόστος της σωστής ταξινόμησης.

Το πρόβλημα της ταξινόμησης τότε γίνεται :

Δοσμένων των :  $\mathbf{p}(\omega_i), \mathbf{p}(\mathbf{x}|\omega_i)$  και  $L_{ij}$  να βρεθεί η συνάρτηση απόφασης που ελαχιστοποιεί το κόστος.

Η συνολική απώλεια  $T_j(\mathbf{x})$  απ' την ταξινόμηση ενός δείγματος στην τάξη  $\omega_j$  είναι :

$$T_j = \sum_{i=1}^K L_{ij} p(\omega_i | \mathbf{x})$$

σε σύνολο  $K$  τάξεων .

Κάθε όρος στο άθροισμα είναι η απώλεια  $L_{ij}$  σταθμιζόμενη απ' την πιθανότητα του δείγματος  $\mathbf{x}$  να ανήκει στην τάξη  $\omega_i$ . Η συνάρτηση απόφασης τότε είναι η ανάθεση του  $\mathbf{x}$  στο  $T_j$  έτσι ώστε το  $T_j$  να έχει την μικρότερη τιμή για κάθε  $j=1$  ως  $K$  .

Αυτό ισοδυναμεί με την εύρεση της ελάχιστης τιμής του αθροίσματος για όλα τα  $j$ .

Υλοποιώντας τον ταξινομητή με μία **0/1 συνάρτηση απώλειας** έχουμε :

$$L_{ij} = \begin{cases} 0 & \text{if } i = j \\ 1 & \text{if } i \neq j \end{cases}$$

Μ' αυτή τη συνάρτηση απώλειας δεν υπάρχει απώλεια για σωστή ταξινόμηση, και η ταξινόμηση ισούται με την εσφαλμένη ταξινόμηση κάποιου pixel σε διαφορετική τάξη απ' αυτήν που ανήκει .

Η συνολική απώλεια απ' την ταξινόμηση ενός δείγματος σε μία τάξη  $\omega_i$  είναι :

$$\begin{aligned} T_j &= \sum_{i=1, i \neq j}^K p(\omega_i | \mathbf{x}) \\ &= \sum_{i=1}^K p(\omega_i | \mathbf{x}) - p(\omega_j | \mathbf{x}) \\ &= 1 - p(\omega_j | \mathbf{x}) \\ &= 1 - \frac{p(\mathbf{x} | \omega_j) p(\omega_j)}{p(\mathbf{x})} \end{aligned}$$

Κι' εδώ η πιθανότητα  $\mathbf{p}(\mathbf{x})$  είναι σταθερή και ανεξάρτητη του  $i$ .

Έτσι η ελάχιστη τιμή του  $T_j$  αντιστοιχεί στη μέγιστη τιμή της πιθανότητας  $\mathbf{p}(\mathbf{x}|\omega_j)\mathbf{p}(\omega_j)$ .

Έτσι ο **Bayes** ταξινομητής με **0/1** συνάρτηση απώλειας ισοδυναμεί με τον **Maximum Likelihood** ταξινομητή.

Τέλος θα δούμε πως αντιμετωπίζουμε τις πιθανότητες  $\mathbf{p}(\omega_j)$  για κάθε τάξη.

Αυτές οι πιθανότητες είναι άγνωστες αλλά απαιτούνται στις συναρτήσεις απόφασης όπως ήδη έχουμε δει .

Μία μέθοδος είναι να απλοποιήσουμε τη συνάρτηση απόφασης, όπως για παράδειγμα του Maximum Likelihood, αδιαφορώντας γι' αυτές τις πιθανότητες .

Έτσι η συνάρτηση θα γίνει :

**Αν  $p(x|\omega_i) > p(x|\omega_j)$  για κάθε  $j, i \neq j$  ταξινόμησε το  $x$  στην  $\omega_i$ .**

Αυτό είναι ισοδύναμο με τον Bayes ταξινομητή με συνάρτηση απώλειας :

$$L_{ij} \begin{cases} = 0 & \text{if } i = j \\ \propto 1 & \text{if } i \neq j \end{cases}$$

Αυτό σημαίνει οτι η απώλεια απο λάθος ταξινόμηση, σπανίως εμφανιζόμενης τάξης είναι πιο σημαντική απ' τις απώλειες άλλων τάξεων.

Στην πραγματικότητα η παραπάνω συνάρτηση απόφασης είναι αυτή που χρησιμοποιείται συνήθως στην πράξη.

Σε κάποια συστήματα ταξινόμησης του εμπορίου ο ταξινομητής εσφαλμένα ονομάζεται Maximum Likelihood ταξινομητής ενώ στην πραγματικότητα είναι ένας Bayes ταξινομητής με την παραπάνω συνάρτηση απώλειας.

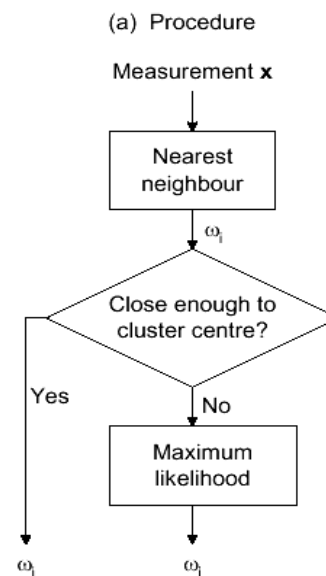
Το λεπτό σημείο της Bayes συνάρτησης απόφασης είναι ο υπολογισμός της πιθανότητας  $p(x|\omega_i)$  για κάθε τάξη  $\omega_i$ .

Η **Nearest Neighbour** συνάρτηση απόφασης όντας λιγότερα ακριβής δεν έχει αυτό το πρόβλημα .


Είναι πιθανό να έχουμε ένα σύστημα το οποίο θα εξερευνά τα πλεονεκτήματα και των δύο μεθόδων.

Μία κοινή πρακτική είναι να συνδέσουμε τις δύο συναρτήσεις όπως φαίνεται στο παρακάτω διάγραμμα :

**Διαγρ . 14** Ο συνδυασμός και των δύο συναρτήσεων απόφασης , Nearest Neighbour και Bayes Classifier



Αυτό που μένει είναι να προσδιορίσουμε την συνθήκη “close enough”.



*Εικ . 27 Τα ιστογράμματα δύο τάξεων για μια συγκεκριμένη ζώνη με το σκιαζόμενο κομμάτι να δείχνει τις “close enough” περιοχές των δύο τάξεων.*

Το εύρος ένταση  $I_i$  σε κάθε περιοχή δίνεται απ’ την  $|I_i - \mu_i| < a \sigma_i$ , όπου  $\mu_i$  και  $\sigma_i$  είναι το μέσο και η τυπική απόκλιση της τάξης  $\omega_i$  και  $a$  μία σταθερά .

Η σταθερά  $a$  μας δείχνει το **βαθμό εμπιστοσύνης** στη **Nearest Neighbour** συνάρτηση απόφασης και αυτό σαν συνάρτηση του  $a$  μπορεί να ανακτηθεί πολύ εύκολα για μια **Gaussian** κατανομημένη συνάρτηση. Αν μία και μόνο ζώνη διαπεύσει την παραπάνω ανισότητα τότε αναλαμβάνει η **Bayes** decision function και το αποτέλεσμα μπορεί να είναι ή και όχι η τάξη  $\omega_i$ .

## 5.7 Fisher's Linear Discriminant

Για να αποφευχθεί το πρόβλημα του Euclidean Distance με τις ίσες αποστάσεις όλων των σημείων μιας τάξης με το κέντρο της, ο αλγόριθμος Fisher's Linear Discriminant (FLD) ενεπλέκει στην εξίσωση δεδομένα συμμεταβλητότητας ,έτσι η εξίσωση μας παρέχει πληροφορίες και για τη σχέση μεταξύ των φασματικών ζωνών.

Μ’αυτά τα επιπλέον δεδομένα στην εξίσωση παίρνουμε καλύτερα αποτελέσματα απ’ την Euclidean distance.

$$g_i(x) = -(X - M_i)^T \hat{\Sigma}_c^{-1} (X - M_i)$$

Θεωρεί όμως ότι η συμμεταβλητότητες των τάξεων είναι ίσες, έτσι ένα πρόβλημα παρουσιάζεται όταν αυτές αρχίζουν να αλλάζουν οπότε και τα δεδομένα αυτά δεν είναι πλέον αντιπροσωπευτικά για κάθε τάξη.

## 5.8 Mahalanobis Distance

Η κυρίως διαφορά ανάμεσα στις Mahalanobis Distance και Fisher Linear Discriminant είναι ότι η στη Mahalanobis κάθε σύνολο (τάξη) έχει τη δικιά του συμμεταβλητότητα (covariance).

Στη FLD η ίδια data covariance χρησιμοποιείται για όλες τις τάξεις. Έτσι η Mahalanobis Distance παρέχει, με τη συμμεταβλητότητα της κάθε τάξης, τη δυνατότητα για ταξινόμηση των συνόλων με διαφορετικές κατανομές στα δεδομένα τους, οπότε και με μεγαλύτερη ακρίβεια.

$$g_i(x) = -(X - M_i)^T \hat{\Sigma}_i^{-1} (X - M_i)$$

όπου  $\hat{\Sigma}_i^{-1}$  ο αντίστροφος του πίνακα συμμεταβλητότητας για την τάξη  $i$ .

## 5.9 Null Class

Στην πράξη πάντα πρέπει να επιτρέπουμε την ύπαρξη μηδενικών τάξεων. Τα μετρούμενα διανύσματα των δειγμάτων σ' αυτές τις τάξεις απέχουν πάρα πολύ απ' τις υπάρχουσες ομάδες στο χαρακτηριστικό πεδίο, ώστε να καθίσταται ανέφικτη η ταξινόμησή τους σε κάποια απ' τις υπάρχουσες τάξεις.

Μία κοινή πρακτική είναι να ελέγχουμε αν οι μετρήσεις σε κάθε ζώνη υπερβαίνουν κατά έναν παράγοντα την τυπική απόκλιση των εντάσεων των pixels σ' αυτή την ζώνη.

Έστω το μετρούμενο διάνυσμα για ένα δείγμα  $x$  προς ταξινόμηση είναι :

$$x = [x(1), x(2), x(3), \dots, x(N)]^T$$

Υποθέτουμε  $N$  φασματικές ζώνες οπότε το χαρακτηριστικό πεδίο είναι  $N$ -διάστατο.

Για κάθε τάξη  $\omega_i$  το μέσο διάνυσμα  $\mu_i$  είναι :

$$\mu_i = [\mu_i(1), \mu_i(2), \mu_i(3), \dots, \mu_i(N)]^T$$

και η τυπική απόκλιση :

$$\sigma_i = [\sigma_i(1), \sigma_i(2), \sigma_i(3), \dots, \sigma_i(N)]^T$$

Κάθε στοιχείο είναι η τετραγωνική ρίζα του αντίστοιχου διαγώνιου στοιχείου στον πίνακα συμμεταβλητότητας.

Αν το διάνυσμα  $x$  πρόκειται να ταξινομηθεί σε μία τάξη  $\omega_i$  τότε ταξινομείται σε μηδενική τάξη αν :

$$|x(j) - \mu_i(j)| > k \sigma_i(j) \text{ για κάθε } j=1 \text{ ως } N.$$

Η  $k$  είναι μία προκαθορισμένη απ'το διαχειριστή σταθερά και συνήθως διακυμαίνεται από 2 ως 3.

Η παραπάνω συνθήκη ελέγχεται επαναληπτικά για το δείκτη  $j$ .

Όταν η συνθήκη ικανοποιηθεί το δείγμα ταξινομείται σε μηδενική τάξη χωρίς περαιτέρω έλεγχο για τον εναπομείναντα δείκτη  $j$  για την τάξη  $\omega_j$ .

## 5.10 Isodata Classifier

Απ'τις πιο δημοφιλής ίσως μεθόδους **Unsupervised** ταξινόμησης είναι η μέθοδος **ISODATA (Iterative Self-Organizing Data Analysis Techniques)**, με το τελευταίο **a** να προστίθεται χάριν ευφωνίας .

Δύο διαφορετικά ονόματα με τα οποία συναντάμε τη μέθοδο αυτή στη βιβλιογραφία είναι **ISOCLASS** και **Migrating Mean**.

Ο αλγόριθμος **ISODATA** φαίνεται στον παρακάτω ψευδοκώδικα :

```
DOPROC initialize cluster centres
DUNTIL satisfied (outer loop)
  IF not first time
    DOPROC delete classes
    DOPROC split classes
    DOPROC combine classes
  ENDIF
  DUNTIL satisfied (inner loop)
    DOPROC apply nearest neighbour decision function
    DOPROC compute new cluster centres
  ENDDO (inner loop)
  DOPROC compute sigma vector of each class
  DOPROC compute distance matrix between classes
ENDDO (outer loop)
DOPROC perform final classification
```

Κάθε μία απ'τις procedures αναλύεται στη συνέχεια.

**Initialize Cluster Centres** : Σ'αυτή τη διαδικασία η διαγώνιος του πολυδιάστατου χαρακτηριστικού πεδίου διαιρείται σε  $k$  τμήματα, όπου  $k$  είναι ο αριθμός των αρχικών τάξεων. Τα σημεία των μέσων των τμημάτων αυτών αποτελούν τα κέντρα των ομάδων (**cluster centres**). Στο τέλος της διαδικασίας αυτής ο αλγόριθμος διακλαδίζεται στον εσωτερικό βρόχο (**inner loop**).

**Delete Classes** : Αυτή η διαδικασία και οι ακόλουθες δύο εκτελούνται αν ο εξωτερικός επαναληπτικός βρόχος έχει εκτελεστεί τουλάχιστον μία φορά. Εδώ ο αριθμός των δειγμάτων σε κάθε τάξη συγκρίνεται με έναν προκαθορισμένο αριθμό  $N_d$ . Αν ο αριθμός υπερβαίνει τον  $N_d$  η αντίστοιχη τάξη διαγράφεται.



**Split Classes** : Σ' αυτό το στάδιο η τυπική απόκλιση της κάθε ζώνης για κάθε τάξη είναι διαθέσιμη (compute sigma vector of each class).

Για κάθε τάξη  $\omega_i$  βρες τη ζώνη με τη μέγιστη τυπική απόκλιση και θέσε την σαν  $\sigma$  στη ζώνη  $j$ .

Επέλεξε  $k$  τάξεις και για κάθε τάξη το μέσο διάνυσμα δίνεται απ' την

$$\mu_i = [\mu_i(1), \mu_i(2), \mu_i(3), \dots, \mu_i(N)]$$

Αν το  $\sigma$  είναι μεγαλύτερο από μια προκαθορισμένη τιμή  $\sigma_s$  τα νέα κέντρα δημιουργούνται στα :

$$[\mu_i(1), \mu_i(2), \dots, \mu_i(j) - \sigma, \dots, \mu_i(N)]^\tau$$

και

$$[\mu_i(1), \mu_i(2), \dots, \mu_i(j) + \sigma, \dots, \mu_i(N)]^\tau$$

**Combine Classes** : Σ' αυτό το στάδιο οι αποστάσεις μεταξύ ζευγών των τάξεων είναι διαθέσιμες. Εδώ οι αποστάσεις μεταξύ κάθε ζεύγους τάξεων υπολογίζονται και συγκρίνονται με μια προκαθορισμένη τιμή  $d_c$ .

Αν η απόσταση υπερβαίνει την τιμή της  $d_c$  οι αντίστοιχες τάξεις συνδιάζονται σε μία.

Το νέο κέντρο της τάξης είναι το κέντρο βάρους των δύο παλιών.

**Apply Nearest Neighbour Decision Function** : Αυτή η διαδικασία και η επόμενη επαναλαμβάνονται στον επαναληπτικό βρόχο **inner loop**. Εδώ η **Nearest Neighbour** συνάρτηση απόφασης (**nearest cluster centre**) εφαρμόζεται σε όλα τα **training samples**.

**Compute New Cluster Centres** : Μετά την ανάθεση των pixels στις αντίστοιχες τάξεις τους στην προηγούμενη διαδικασία, υπολογίζονται τα νέα κέντρα. Σημειώνουμε ότι μετά από κάθε επανάληψη του **inner loop** τα **cluster centres** μεταναστεύουν σε νέες θέσεις (εξ ου και **migrating means**).

**Compute Sigma Vector Of Each Class** : Με τις νέες τάξεις υπολόγισε για κάθε τάξη το διάνυσμα που περιέχει την τυπική απόκλιση για κάθε ζώνη.

**Compute Distance Matrix Between Classes** : Υπολογίζονται οι αποστάσεις μεταξύ των ζευγών των τάξεων και αναπαριστώνται σε μορφή πίνακα. Το στοιχείο της  $j$  γραμμής και  $i$  στήλης αντιστοιχεί στην απόσταση μεταξύ των τάξεων  $\omega_j$  και  $\omega_i$ . Ο πίνακας είναι προφανώς συμμετρικός ως προς τη διαγώνιο.

**Perform Final Classification** : Σ' αυτό το σημείο η διαδικασία του **training** έχει ολοκληρωθεί. Η ταξινόμηση του κάθε pixel στις αντίστοιχες τάξεις μπορεί να πραγματοποιηθεί εφαρμόζοντας τον κανόνα του **Nearest Neighbourhood**.

Στον ψευδοκώδικα υπάρχουν δύο επαναληπτικοί βρόχοι **outer loop** και **inner loop**. Το **training** επιτυγχάνεται στο τέλος του **outer loop** όταν τα **cluster centres** ικανοποιούν τον διαχειριστή.

Κατά τη διαδικασία εκπαίδευσης δε χρησιμοποιούμε ολόκληρη την εικόνα.

Ο διαχειριστής μπορεί να ορίσει συγκεκριμένες θέσεις pixels απ' τις οποίες θα αντλεί τα δείγματα, για παράδειγμα ένα δείγμα ανα μία 5x5 περιοχή εξοικονομώντας έτσι υπολογιστικό χρόνο.

Κάθε βρόχος εκτελείται αρκετές φορές με βάση την υποκειμενική εκτίμηση του διαχειριστή. Συνήθως ο inner loop αρκείται στις 3 φορές ενώ ο outer loop επαναλαμβάνεται περισσότερες.

Ο διαχειριστής πρέπει να ορίσει τρεις μεταβλητές πριν εκτελέσει τα βήματα στον αλγόριθμο και αυτές είναι οι **Nd**, **σs** και **dc**.

## 5.11 Spectral Angle Mapper (SAM)

Ο αλγόριθμος **SAM (spectral angle mapper)** επίσης θεωρεί κάθε pixel σαν ένα διάνυσμα στο n-διάστατο χώρο με n τον αριθμό των καναλιών στην εικόνα. Κάθε διάνυσμα έχει συγκεκριμένο μήκος και κατεύθυνση.

Το μήκος του διανύσματος αναπαριστά τη φωτεινότητα του στόχου ενώ η κατεύθυνσή του τα φασματικά του χαρακτηριστικά.

Οι μεταβολές στο φωτισμό επηρεάζουν όμως το μήκος του διανύσματος οπότε η ταξινόμηση γίνεται με βάση την κατεύθυνσή του (Kruse et al., 1993).

Η φασματική υπογραφή (**spectral signature**) του κάθε pixel περιγράφεται από την γωνία που σχηματίζει το αντίστοιχο διάνυσμα, με τον άξονα που ορίζει το n-διάστατο χώρο στην εικόνα.

Η ταξινόμηση πραγματοποιείται συγκρίνοντας τις φασματικές γωνίες ανάμεσα στο φάσμα ανάκλασης του pixel που θα ταξινομηθεί με τα φάσματα αναφοράς από τις φασματικές βιβλιοθήκες ή με το φάσμα αναφοράς από τα training data.

Στη δεύτερη περίπτωση ένα μέσο διάνυσμα υπολογίζεται για κάθε τάξη και όλα τα διανύσματα των pixels ταξινομούνται με βάση τη μικρότερη γωνία που σχηματίζουν με το κάθε διάνυσμα τάξης.

Ένα όριο μέγιστης γωνίας μπορεί να οριστεί ώστε κάθε pixel το οποίο ξεπερνά αυτήν την γωνία με όλες τις τάξεις, να μην ταξινομείται.

Ο SAM αλγόριθμος δεν μπορεί να κάνει διάκριση ανάμεσα σε θετικές ή αρνητικές συσχετίσεις επειδή λαμβάνει υπόψην του μόνο τις απόλυτες τιμές.

Ο **Spectral Corellation Mapper (SCM)** για να διορθώσει αυτήν την αδυναμία του SAM απλά τυποποιεί τα διανύσματα των φασμάτων ανάκλασης πριν υπολογίσει τις φασματικές γωνίες (Carvalho and Meneses, 2000).

Για την καλύτερη κατανόηση του αλγορίθμου **SAM** θεωρούμε ένα φάσμα αναφοράς και ένα άγνωστο φάσμα από δεδομένα δύο ζωνών.

Τα δύο υλικά θα αναπαριστώνται στο δισδιάστατο χώρο από ένα σημείο για μια δοσμένη τιμή φωτεινότητας ή σαν ένα διάνυσμα για όλες τις δυνατές τιμές φωτεινότητας.

Επειδή η μέθοδος χρησιμοποιεί μόνο τη κατεύθυνση, και όχι το μήκος του διανύσματος, δεν επηρεάζεται από τις διάφορες τιμές φωτεινότητας και τις αντιμετωπίζει όλες εξ'ίσου.

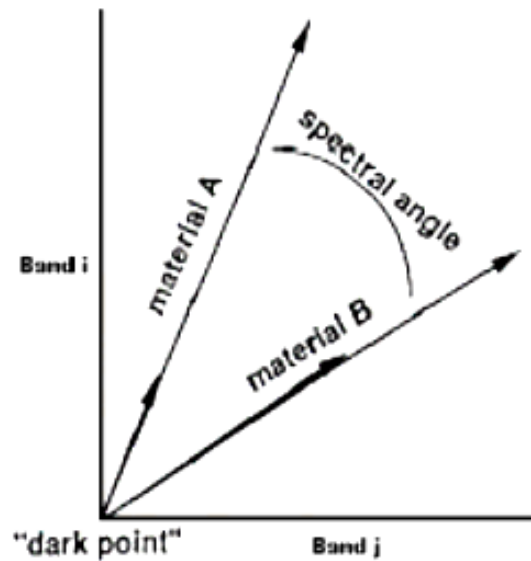
Τα πιο φτωχά φωτισμένα pixels απλά θα βρίσκονται πιο κοντά στην αρχή των αξόνων. Το μήκος των διανυσμάτων δεν επηρεάζει τη μεταξύ τους γωνία.

Ο αλγόριθμος γενικεύει αυτή τη γεωμετρική αναπαράσταση στο N-διάστατο χώρο και προσδιορίζει την ομοιότητα ενός αγνώστου φάσματος  $\mathbf{t}$  με ένα φάσμα αναφοράς  $\mathbf{r}$ , εφαρμόζοντας τις παρακάτω εξισώσεις :

$$\alpha = \cos^{-1} \left( \frac{\mathbf{t} \bullet \mathbf{r}}{\|\mathbf{t}\| \cdot \|\mathbf{r}\|} \right)$$

η οποία μπορεί να γραφτεί και :

$$\alpha = \cos^{-1} \left( \frac{\sum_{i=1}^{nb} t_i r_i}{\left( \sum_{i=1}^{nb} t_i^2 \right)^{1/2} \left( \sum_{i=1}^{nb} r_i^2 \right)^{1/2}} \right)$$



(Kruce et al., 1993).

όπου nb, ο αριθμός των φασματικών ζωνών .

**Εικ . 28** Η λογική του αλγορίθμου Spectral Angle Mapper

## 5.12 Ασαφείς μέθοδοι ταξινόμησης

Οι unsupervised και supervised μέθοδοι ταξινόμησης θεωρούνται αυστηροί ταξινομητές (**hard classifiers**) αφού υποχρεώνουν όλα τα pixels σε ταξινόμηση διακριτών τάξεων.

Οι ασαφείς (**fuzzy**) μέθοδοι ταξινόμησης όμως θέτουν ένα σύνολο πιθανοτήτων σε κάθε pixel ανάλογα με την τάση του να ανήκει σε κάποια τάξη.

Αυτή η πληροφορία στη συνέχεια μπορεί να χρησιμοποιηθεί για έναν πιο σαφή ορισμό τάξεων περιλαμβανομένων και τάξεων αναμεμιγμένων pixels (Jensen, 1996).

Υπάρχουν αρκετοί αλγόριθμοι ασαφούς ταξινόμησης όπως : **Linear Spectral Unmixing**, **Mixed Tuned Matched Filtering (MTMF)**, και **Spectral Feature Fitting (SFF)**.

### 5.12.1 Linear Spectral Unmixing

Η **Linear Spectral Unmixing** τεχνική βασίζεται στην υπόθεση ότι η φασματική ανάκλαση κάθε pixel είναι ένας γραμμικός συνδυασμός των μοναδικών φασματικών ανακλάσεων όλων των υλικών που υπάρχουν στο pixel σε αναλογία τέτοια ώστε να καλύπτουν όλη την περιοχή του pixel (Menke, 1984).

Γενικά για την πραγματοποίηση του φασματικού διαχωρισμού χρειαζόμαστε τα φάσματα ανάκλασης κάθε τύπου του πεδίου της εικόνας.

Αυτα μπορούν να αποκτηθούν απο τη φυσική τους θέση (**in situ**) με ένα φασματόμετρο πεδίου , ή τα training sets να ορισθούν ανάλογα με τα φάσματα των μελών (**endmembers**), ή με δείγματα «αγνών τύπων» απ'τα αποτελέσματα ενός αλγόριθμου βαθμού αγνότητας pixel (**Pixel Purity Index** ή **PPI**) , τον οποίο θα αναλύσουμε παρακάτω.

Η διαδικασία του **unmixing** ανάγεται στην λύση ενός συνόλου **n γραμμικών εξισώσεων** για κάθε pixel, όπου **n** είναι ο αριθμός των ζωνών στην εικόνα.

Οι άγνωστες μεταβλητές σ'αυτές τις εξισώσεις είναι τα κλάσματα του κάθε **endmember** στο pixel.

Για να λύσουμε αυτές τις εξισώσεις για τα άγνωστα κλάσματα των pixels χρειαζόμαστε περισσότερες εξισώσεις απ'ότι αγνώστους που προυποθέτει την ύπαρξη περισσότερων ζωνών απο endmembers, κάτι που στα υπερφασματικά δεδομένα ισχύει πάντα.

Τα αποτελέσματα του Linear Spectral Unmixing περιλαμβάνουν μία εικόνα για κάθε endmember.

Σ'αυτήν την εικόνα οι τιμές των pixels δείχνουν το ποσοστό του pixel στο οποίο κυριαρχεί αυτό το endmember.

Για παράδειγμα αν ένα pixel στην εικόνα για το endmember A έχει τιμή 0.90 τότε 90% της περιοχής του pixel αποτελείται απ'το endmember A.

### 5.12.2 Pixel Purity Index

Ο αλγόριθμος **PPI** εφαρμόζεται σε ένα μετασχηματισμό λόγου ελαχίστου θορύβου (minimum noise fraction ή MNF) των δεδομένων της εικόνας (Green , 1988).

Ο MNF είναι μετασχηματισμός είναι δύο βημάτων.

Πρώτα πραγματοποιείται μία principal component analysis (PCA) στα δεδομένα για rescaling του θορύβου και κάθε band-to-band συσχέτιση στο θόρυβο αφαιρείται.

Μετά ακολουθεί μία δεύτερη PCA στα δεδομένα και το αποτέλεσμα είναι η MNF μετασχηματισμένη εικόνα .

Η PPI διαδικασία επαναλαμβάνει τους μετασχηματισμούς σε τυχαία μοναδιαία διανύσματα για έναν προκαθορισμένο αριθμό επαναλήψεων (συνήθως  $1 \times 10^4$  ως  $1 \times 10^8$  φορές).

Τα pixels στα άκρα αυτών των διανυσμάτων σημειώνονται με κάθε εναλλαγή.Ο αριθμός εμφάνισης του κάθε pixel καταγράφεται.

Τα αγνότερα pixels έχουν την τάση να εμφανίζονται πιο συχνά έτσι επιλέγουμε και τα πιθανά endmembers (Boardman, 1993., Boardman, 1995).

Τέλος ο χρήστης εναλλάσει αυτά τα pixels στο n-διάστατο χώρο για την ταυτοποίηση των endmember clusters.

Αυτή η μέθοδος είναι εξαιρετικά χρονοβόρα όμως και πολύ χρήσιμη σε υπερφασματικές εφαρμογές όταν δεν είναι διαθέσιμες βιβλιοθήκες φασμάτων για κάθε τύπο υλικών.

### 5.12.3 Mixed Tuned Matched Filtering

Η Mixed Tuned Matched Filtering (Boardman et al., 1995) τεχνική είναι μία **partial unmixing** μέθοδος η οποία δεν απαιτεί να οριστούν όλα τα endmembers της εικόνας .

Ο αλγόριθμος επιστρέφει ένα ποσοστό κάλυψης της εικόνας για κάθε endmember που έχει οριστεί.

Όπως και στη Linear Spectral Unmixing μία τιμή pixel στην εικόνα του αποτελέσματος αναπαριστά το ποσοστό του pixel που περιέχει το υλικό που μας ενδιαφέρει.

Κάθε pixel με τιμή ίση ή μικρότερη του μηδενός θα θεωρείται αδιάφορο.

Ένα πρόβλημα με τη μέθοδο του Matched Filtering είναι ότι μπορεί να καταλήξει σε εσφαλμένα θετικά αποτελέσματα.

Μία λύση είναι ο υπολογισμός μιάς επιπλέον μονάδας μέτρησης , του βαθμού ανεφικτότητας (**infeasibility**).

Ο βαθμός ανεφικτότητας βασίζεται στο θόρυβο και στη στατιστική της εικόνας και παρουσιάζει το βαθμό στον οποίο το Matched Filtering αποτέλεσμα είναι ένα εφικτό μείγμα του στόχου και των υπολοίπων αδιάφορων.

Τα pixels που έχουν υψηλή αυτήν την τιμή έχουν την τάση να έχουν εσφαλμένα θετικές τιμές.

Αν ο στόχος δεν είναι ένα σπάνιο υλικό πρέπει να δώσουμε ιδιαίτερη προσοχή στην εφαρμογή και τα αποτελέσματα του Matched Filtering.

### 5.12.4 Spectral Feature Fitting (SFF)

Οι περισσότερες μέθοδοι που έχουν χρησιμοποιηθεί στην ανάλυση υπερφασματικών δεδομένων δεν αναγνωρίζουν αμέσως συγκεκριμένα υλικά , απλά διευκρινίζουν την ομοιότητα τους με κάποια γνωστά υλικά ή τη μοναδικότητά τους σε σχέση μ'αυτά.

Παρ'όλα αυτά τεχνικές οι οποίες αναγνωρίζουν κατ'ευθείαν κάποια υλικά μέσω εξαγωγής των φασματικών χαρακτηριστικών απο συγκεκριμένα φάσματα ανάκλασης χρησιμοποιούνται εδώ και πολλά χρόνια. (Green and Craig, 1985; Kruse et al., 1985; Yamaguchi and Lyon, 1986; Clark et al., 1987, Clark and Crowley, 1992; Kruse et al. 1993b, 1993c; Kruse and Lefkoff, 1993, Swayze et al., 1995).

Όλες αυτές οι τεχνικές απαιτούν την αφαίρεση ενός συνεχούς τμήματος απ'το φάσμα ανάκλασης πριν την ανάλυση.

Ένα συνεχές (**continuum**) είναι μια μαθηματική συνάρτηση που χρησιμοποιείται για την απομόνωση συγκεκριμένων χαρακτηριστικών ανάκλασης για την ανάλυση.

Αντιστοιχεί σε ένα σήμα υπόβαθρου το οποίο δεν έχει σχέση με τα συγκεκριμένα χαρακτηριστικά ανάκλασης που μας ενδιαφέρουν. Το φάσμα ανάγεται σε μια κοινή μορφή αναφοράς χρησιμοποιώντας μια μορφή συνεχούς.

Αυτό γίνεται εντοπίζοντας τα τοπικά μέγιστα του φάσματος και προσαρμόζοντας ευθύγραμμα τμήματα ανάμεσα στα σημεία αυτά.

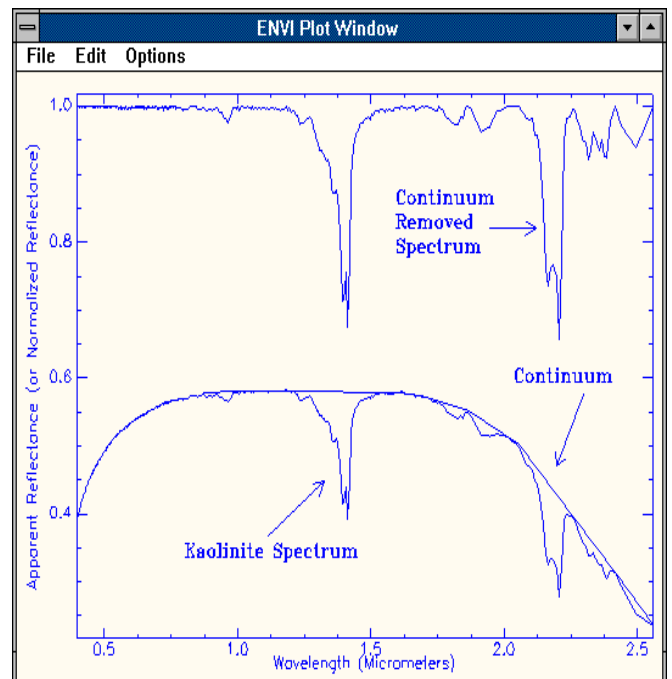
Το συνεχές τότε αφαιρείται διαιρώντας το με το αρχικό φάσμα.

Ο αλγόριθμος **SFF** απαιτεί ότι τα φάσματα των **endmembers** θα έχουν επιλεγθεί είτε απ'την ίδια την εικόνα είτε απο φασματικές βιβλιοθήκες, ότι και στο φάσμα αναφοράς και στο άγνωστο φάσμα θα έχουν αφαιρεθεί τα συνεχή και ότι το κάθε endmember φάσμα αναφοράς θα έχει βαθμονομηθεί ανάλογα για την αντιστοίχισή του με το άγνωστο φάσμα.

Στη συνέχεια συγκρίνει τα δύο φάσματα χρησιμοποιώντας μία μέθοδο ελαχίστων τετραγώνων .

Ο **SFF** επιστρέφει μια *scale image* για κάθε φάσμα αναφοράς η οποία είναι ένα μέτρο του βαθμού αντιστοίχισης του κάθε *spectral signature* με τα φάσματα των *training sets*. Επίσης επιστρέφει μία εικόνα μέσης ενεργής τιμής (**RMS**) σφάλματος για κάθε *training set*.

Η **RMS** εικόνα μπορεί να εξισωθεί γραφικά με την **scale image** του κάθε *endmember* και κάθε *pixel* με χαμηλό **RMS** σφάλμα και υψηλό **scale score** για μια δοσμένη τάξη ταξινομείται στην τάξη αυτή (Albert, 2002).



**Εικ . 29** Εικόνα του προγράμματος **ENVI** (*Environment for Visualizing Images*) για την αφαίρεση του *continuum* του φάσματος .

# Κεφάλαιο 6<sup>ο</sup>

## Συμπεράσματα

### 6.1 Γενικά

Οι υπερφασματικοί αισθητήρες και αναλύτες μας παρέχουν τις περισσότερες πληροφορίες για τηλεσκοπικά δεδομένα (πλέον και όχι μόνο) απ'όσο ήταν ποτέ πιθανό τα προηγούμενα χρόνια.

Καθώς νέοι αισθητήρες παρέχουν περισσότερες υπερφασματικές απεικονίσεις και νέοι αλγόριθμοι επεξεργασίας εικόνας συνεχίζουν να αναπτύσσονται, η υπερφασματική απεικόνιση τείνει να εδραιωθεί σαν μία απ'τις πιο αποτελεσματικές και συνηθισμένες τεχνολογίες έρευνας, εξερεύνησης και παρακολούθησης σε μια πληθώρα επιστημονικών πεδίων.

Οι τεχνικές ταξινόμησης βασικά ποικίλουν ανάλογα με την εκ των προτέρων γνώση που διαθέτουμε για την περιοχή που μας ενδιαφέρει όπως οι supervised και unsupervised ταξινομήσεις.

Οι Unsupervised τεχνικές εφαρμόζονται όταν λίγες ή όχι τόσο λεπτομερές πληροφορίες είναι διαθέσιμες για την κατανομή των υλικών στην περιοχή που μας ενδιαφέρει.

### 6.2 Προβλήματα στην ταξινόμηση

Το πλήθος των φασματικών πληροφοριών που είμαστε πλέον σε θέση να ανακτήσουμε συμβαδίζει με το υψηλό κόστος των υπεράριθμων δεδομένων θέτοντας επίσης νέες μαθηματικές προκλήσεις για την ταξινόμηση εικόνων με υψηλή διαστατικότητα.

Τα βασικά προβλήματα που αντιμετωπίζει η ανάλυση τηλεσκοπικών φασματικών εικόνων προέρχονται απο οποιονδήποτε συνδυασμό των παρακάτω :

- Η υψηλή διαστατικότητα των φασματικών δεδομένων (δεκάδες ως εκατοντάδες φασματικών ζωνών)
- Ο αριθμός των pixels μπορεί να αγγίξει και την τάξη του εκατομμυρίου.
- Τα pixels είναι αναμειγμένα. Πολλά διαφορετικά υλικά συμβάλλουν στο σχηματισμό της φασματικής υπογραφής που ανακτάται απο κάθε pixel.
- Δεδομένου του πλούτου των δεδομένων ο στόχος είναι να διαχωρίσουμε όσες περισσότερες τάξεις μπορούμε.
- Κάποια υλικά μπορούν να διαχωριστούν μόνο απο πολύ λεπτές διαφορές των φασματικών υπογραφών τους
- Περιορισμένος αριθμός απο training data, μπορεί να είναι διαθέσιμος για κάποιες τάξεις και κάποιες απ' αυτές μπορεί να αναπαριστώνται με μεγάλη ανομοιογένεια.

Μία επίσης απ'τις μεγαλύτερες δυσκολίες στην πραγματοποίηση μιας ακριβής ταξινόμησης είναι η αναγνώριση όλων των περιβαντολογικών παραγόντων που επηρεάζουν τη φασματική ανάκλαση των υλικών (Jensen, 1996) .

Η επιλογή ομοιογενών και αντιπροσωπευτικών training sites για supervised και fuzzy αλγόριθμους ταξινόμησης είναι πολλές φορές αρκετά δύσκολο να επιτευχθεί και η ακρίβειά τους επηρεάζει σε μεγάλο βαθμό την απόδοση αυτών των τεχνικών.

Η εναλλακτική πλευρά έχει να κάνει με τη χρήση βιβλιοθηκών φασμάτων, οι οποίες τείνουν να καθιερωθούν, και το διαχωρισμό των endmembers από PPI ανάλυση.

Η τελευταία μπορεί να είναι πολυέξοδη σε επίπεδο πόρων και χρόνου επεξεργασίας.

Μία ακόμη δυσκολία είναι η εκτίμηση της ακρίβειας της ταξινόμησης.

Αυτο συνεπάγεται και τη δυσκολία της επιλογής του πιο ακριβή αλγόριθμου ειδικά όταν κάποιοι περισσότερο πολύπλοκοι αλγόριθμοι δεν παράγουν πάντα και το καλύτερο αποτέλεσμα (Albert, 2002).

Ακόμη η μεγάλη αδυναμία των supervised μεθόδων ταξινόμησης είναι η εξάρτησή τους απ' τα training sites και την υπόθεση της κανονικά κατανομημένης πιθανότητας για κάθε τάξη (Richards και Jia, 1986). Απ' την άλλη οι unsupervised τεχνικές ταξινόμησης χρησιμοποιούν τεχνικές ομαδοποίησης (**clustering**) για να παράγουν τάξεις απο ομαδοποιημένα pixels με κοινά φασματικά χαρακτηριστικά.

Ο χρήστης σ' αυτήν την περίπτωση είναι υπεύθυνος για τον συσχετισμό αυτών των φασματικών ομάδων (**clusters**) με σαφώς ορισμένες τάξεις υλικών (Jensen, 1996).

Αυτό δεν είναι πάντα εύκολο καθώς, όπως προαναφέραμε υπάρχουν ομάδες που αναπαριστούν περισσότερες απο μία τάξεις.

Γενικά πάντως ο χρόνος που απαιτείται για το διαχωρισμό των τάξεων μετά απο ομαδοποίηση σε unsupervised classification είναι πιο μικρός απ' το χρόνο που απαιτείται για τον ορισμό των training sites σε supervised classification (Albert, 2002).

### 6.3 Παράγοντες που επηρεάζουν την ταξινόμηση

Κάποιοι απ' τους παράγοντες που επηρεάζουν τα αποτελέσματα ταξινόμησης είναι η διαθεσιμότητα των τηλεσκοπικών δεδομένων, η πολυπλοκότητα του τοπίου, η διαστατικότητα του χαρακτηριστικού πεδίου, οι αλγόριθμοι ταξινόμησης που χρησιμοποιούνται, η γνώση των αναλυτών για τη μελετώμενη περιοχή και η εμπειρία τους με τους συγκεκριμένους ταξινομητές (Densheng et al., 2004).

**Training Set:** Το πιο σημαντικό ζήτημα στην supervised ταξινόμηση είναι η επάρκεια των training data στο χαρακτηρισμό των ιδιοτήτων της επιλεγμένης τάξης αφού το training set έχει αξιοσημείωτη επιρροή στην ακρίβεια των αποτελεσμάτων ταξινόμησης (Campbell, 1996).

Προηγούμενες μελέτες έδειξαν ότι το μέγεθος του training set παίζει καθοριστικό ρόλο στην ακρίβεια της ταξινόμησης.

Δεν υπάρχει κάποιος σταθερός αριθμός που να ορίζει το μέγεθος αυτό αλλά εξαρτάται απ' τον αριθμό των clusters που θα ταξινομηθούν, τον ίδιο τον ταξινομητή, τη διαστατικότητα του χαρακτηριστικού πεδίου και την ομοιογένεια της περιοχής.

Η απόκτηση τέτοιων μεγάλων training sets μπορεί να είναι δύσκολη και ακριβή όταν έχουμε να κάνουμε με μεγάλο αριθμό τάξεων (Pal και Paul, 2003).

Τα αποτελέσματα της ταξινόμησης γίνονται χειρότερα όταν το μέγεθος της περιοχής που μας ενδιαφέρει αυξάνεται (Wilkinson, 2005).

Έχουμε αντιληφθεί ότι η σημαντική προϋπόθεση για την αποτελεσματικότητα του Maximum Likelihood είναι ο αριθμός των pixels που περιλαμβάνονται στο training data set για κάθε τάξη, ο οποίος πρέπει να είναι 10-30 φορές μεγαλύτερος του αριθμού των χαρακτηριστικών (Tso και Mather, 2001).



Μία ακόμη έρευνα (Pal και Paul, 2003), έδειξε οτι ταξινομητές βασισμένοι σε τεχνητά νευρωνικά δίκτυα (**ANN-based classifiers**) μπορούν να εκτελεστούν επιτυχώς χρησιμοποιώντας μικρότερα training data sets απ'αυτά που απαιτούνται για την εκπαίδευση στατιστικών ταξινομητών.

**Διαστατικότητα του χώρου χαρακτηριστικών:** Για στατιστικούς ταξινομητές το φαινόμενο Hughes μας λέει οτι για σταθερό μέγεθος training data set , όταν ο αριθμός των χαρακτηριστικών αυξάνει η απόδοση του ταξινομητή μειώνεται.

Η αύξηση των χαρακτηριστικών μας παρέχει περισσότερες πληροφορίες για να καθορίσουμε τα όρια απόφασης (decision boundaries), αλλά αυτές οι πληροφορίες είναι χρήσιμες μόνο όταν ο αριθμός των training data αυξάνεται αναλογικά (Pal και Paul, 2003).

Όταν η διαστατικότητα του χαρακτηριστικού πεδίου μεγαλώνει είναι σαφές οτι η ακρίβεια του ταξινομητή βελτιώνεται (Wilkinson, 2005).

**Αριθμός των Clusters:** Απο τη βιβλιογραφία σύμφωνα με διάφορες έρευνες που έχουν γίνει καταλήξαμε στο οτι όσο μεγαλώνει ο αριθμός των τάξεων που χρησιμοποιούνται σε ένα πείραμα ταξινόμησης τόσο πιο δύσκολη και ανακριβής γίνεται η ταξινόμηση (Wilkinson, 2005).

**Χωρική Ανάλυση:** Η ακρίβεια της ταξινόμησης σαφώς επηρεάζεται απ'την χωρική ανάλυση του αισθητήρα (Wilkinson, 2005).

## 6.4 Εναλλακτικές τεχνικές

Αρκετές νέες τεχνικές ψηφιακής ανάλυσης εικόνας για ταξινόμηση τηλεσκοπικών δεδομένων έχουν εισαχθεί τα τελευταία χρόνια.

Σημαντικά ήταν : η εκμετάλλευση της διακύμανσης των endmembers στα training sets η οποία βελτίωσε κατα ένα μεγάλο βαθμό τη spectral mixture analysis (Bateson,2000),η αξιοποίηση των νευρωνικών δικτύων για τη δημιουργία ενός self-organizing road map αλγόριθμου ο οποίος εξάγει επιμηκημένα road-features απο πολυφασματικά δεδομένα (Doucette 2001) αλλά και η χρήση τεχνικών edge-detection.

Οι Hubert και Moy (2000) παρουσίασαν μία πρωτότυπη παραμετρική μέθοδο ταξινόμησης για την ταυτοποίηση και τον καθορισμό εδάφους.

Ο Steele (2000) χρησιμοποίησε συνδυασμούς πολλαπλών μεθόδων ταξινόμησης για τον ίδιο σκοπό.

Αυτές οι νέες τεχνολογίες καθώς και πλήθος άλλων που συνεχίζουν να εμπλουτίζουν την επιστήμη της ταξινόμησης αποτελούν ελπιδοφόρες ενδείξεις για περισσότερα και πιο ακριβή αυτόματα συστήματα ταξινόμησης στο μέλλον.

Τα αντικείμενα μελέτης για την υπερφασματική απεικόνιση το 2004 ήταν κυρίως :

- **Η μελέτη διαφορετικών μεθόδων συλλογής φασμάτων αναφοράς**
- **Η αξιολόγηση της εφαρμοσιμότητας και χρηστικότητας των φασμάτων αναφοράς**
- **Να ανακαλυφθούν και να δοκιμαστούν νέοι τρόποι απεικόνισης των υπερφασματικών δεδομένων**
- **Η ανάπτυξη και δοκιμή νέων αλγορίθμων ταξινόμησης των υπερφασματικών δεδομένων.**

### 6.4.1 Ανάπτυξη του παραλληλισμού

Οι υπερφασματικοί αλγόριθμοι απαιτούν πολύ υψηλά επίπεδα υπολογιστικής παραγωγής (computational throughput).

Αυτοί οι τύποι αλγορίθμων όταν εκτελούνται σε κοινά workstations ή σε multiprocessors server περιβάλλοντα μπορεί να χρειαστούν και μέρες για να ολοκληρωθούν.

Οι σημερινές έρευνες έχουν επικεντρωθεί στην εξαγωγή καλύτερων αποτελεσμάτων συνδυάζοντας διαφορετικούς αλγόριθμους και προσεγγίσεις αλλά έτσι η πολυπλοκότητα και το υπολογιστικό φόρτο αυξάνεται.

Μία λύση που έχει προταχθεί είναι ο παραλληλισμός και η κατανομή διαφόρων αλγορίθμων μείωσης της διαστατικότητας και ταξινόμησης.

Οι περισσότεροι αλγόριθμοι προβάλλουν το γεγονός ότι κάθε ταξινόμηση pixel είναι ανεξάρτητη απ'την κάθε άλλη.

Αυτό είναι ένα χαρακτηριστικό που μπορεί να προωθήσει τον παραλληλισμό.

Πως όμως η επικοινωνία αυτών των τεράστιων συνόλων δεδομένων επηρεάζει τον παραλληλισμό;

Οι έρευνες έχουν στραφεί στα εξής :

- Να αποδειχθεί ότι η εξαντλητική αναζήτηση σε υποσύνολα συνδιασμένων χαρακτηριστικών είναι εφικτή σε λογικούς χρόνους εκτέλεσης.
- Να ολοκληρωθεί η ανάλυση της ταξινόμησης εικόνας σε παράλληλο περιβάλλον και να προταθούν λύσεις οι οποίες θα λαμβάνουν υπόψιν τους τη χωρική αλλά και φασματική ανάλυση της εικόνας αλλά και τον αριθμό των τάξεων.
- Να βρεθούν τρόποι με τους οποίους τα χαρακτηριστικά των υπερφασματικών αλγορίθμων θα προωθήσουν την ανάπτυξη του παραλληλισμού.

### 6.4.2 Τεχνικές ελεύθερης κατανομής

Στις τηλεσκοπικές εφαρμογές οι πιο δημοφιλείς μέθοδοι ελεύθερης κατανομής είναι τα **δέντρα απόφασης** (decision trees) και τα **νευρωνικά δίκτυα** (neural networks).

Τα νευρωνικά δίκτυα κατέχουν το πλεονέκτημα της μη παραμετρικής μεθόδου.

Κάποια επιπλέον, μη τηλεσκοπικά δεδομένα μπορούν να ταξινομηθούν πιο εύκολα χρησιμοποιώντας μη παραμετρικές μεθόδους (Mather, 1999).

Απ'την άλλη τα νευρωνικά δίκτυα μπορούν να έχουν πολύ υψηλή υπολογιστική πολυπλοκότητα,χρειάζονται μεγάλο αριθμό training samples για να εφαρμοστούν επιτυχώς και οι επαναληπτικές διαδικασίες εκπαίδευσης τους απαιτούν πολύ χρόνο για να συγκλίνουν (Benediktsson et al., 1990).

Η απόδοση επομένως των νευρωνικών δικτύων εξαρτάται περισσότερο απ'τη διάθεση αντιπροσωπευτικών δειγμάτων εκπαίδευσης ενώ οι στατιστικές προσεγγίσεις πρέπει να διαθέτουν ένα κατάλληλο μοντέλο για κάθε τάξη (Benediktsson et al., 1990).

Για την επίλυση της «διαταξικής» σύγχυσης που υπάρχει στα τεχνικά νευρωνικά δίκτυα και τα δέντρα απόφασης,μέθοδοι οι οποίες προέρχονται απ'το σύνολο της fuzzy θεωρίας,όπως η ενσωμάτωση δευτερεύουσας πληροφορίας όπως η υφή,το περιβάλλον και τα χαρακτηριστικά της περιοχής,σε υβριδικά συστήματα έχουν χρησιμοποιηθεί σαν εναλλακτικές (Tso and Mather, 2001).

Η λογική ταξινόμησης του fuzzy συνόλου, η οποία λαμβάνει υπόψη την ετερογενή και ανακριβή φύση του πραγματικού κόσμου, μπορεί να χρησιμοποιηθεί παράλληλα με supervised και unsupervised αλγόριθμους ταξινόμησης.

Κάποιες φορές είναι απαραίτητο να συμπεριλάβουμε μη φασματικά, συμπληρωματικά δεδομένα όταν εφαρμόζουμε μία supervised, unsupervised, και/ή fuzzy ταξινόμηση για να εξάγουμε την επιθυμητή πληροφορία (Jensen, 1996).

### 6.4.3 Support Vector Machines

Σημαντική είναι και η χρήση των Support Vector Machines (SVMs), μία supervised προσέγγιση για την ταξινόμηση.

Οι SVMs αποτελούν καλούς υποψήφιους για supervised μη παραμετρική ταξινόμηση. Οι SVMs ανήκουν στην ομάδα των machine learning αλγορίθμων.

Η υψηλή τους ικανότητα γενίκευσης έχει εμπνεύσει προόδους στη βελτίωση του υπολογιστικού χρόνου.

Έχει αποδειχτεί ότι για τον ίδιο αριθμό απο training samples οι SVMs έχουν καλύτερη απόδοση στην ταξινόμηση από άλλους ανταγωνιστικούς αλγόριθμους.

Η ταξινόμηση με SVMs δεν απαιτεί προεπεξεργασία των δεδομένων για μείωση της διαστατικότητας, εντούτοις χρησιμοποιεί τα δεδομένα σε όλες τις διαστάσεις για να παράγει ταξινομήσεις που έχουν την ακρίβεια της τάξης των 97%.

### 6.4.4 Θέματα αναπαράστασης

Για ευκολία στην ταξινόμηση τα φάσματα αναπαριστώνται σαν σημεία στο πολυδιάστατο χώρο.

Το μειονέκτημα αυτής της προσέγγισης είναι ότι χάνεται η φασματική συνδετικότητα.

Χαρακτηριστικά όπως η μορφή του φάσματος ή η θέση των κορυφών είναι δύσκολο να χρησιμοποιηθούν σε ένα τέτοιο χαρακτηριστικό πεδίο.

Σε περιπτώσεις που αυτά τα χαρακτηριστικά είναι πολύ χρήσιμα για την ταξινόμηση μεγάλα σύνολα δεδομένων και πολύπλοκες στατιστικές διαδικασίες πρέπει να αναπτυχθούν για την ανάκτησή.

Μία εναλλακτική προσέγγιση είναι η αναπαράσταση του φάσματος με βάση τις διαφορές του με άλλα φάσματα.

Ζεύγη φασμάτων συγκρίνονται με βάση ένα κριτήριο ανομοιότητας, και για ένα δοσμένο training set παράγεται ένας τετραγωνικός πίνακας ζευγών ανομοιότητας σχηματίζοντας έτσι μία εναλλακτική αναπαράσταση η οποία μπορεί να αντιληφθεί το φάσμα σαν μία συνδεδεμένη οντότητα και να δώσει έμφαση σε χαρακτηριστικά όπως αυτά που αναφέραμε, προσδοκώντας τη βελτίωση του υπολογιστικού χρόνου.

### 6.4.5 Αντικειμενοστρεφής Ταξινόμηση (Object-oriented Classification)

Παραδοσιακά η ταξινόμηση εικόνας βασίζεται στην επεξεργασία της εικόνας “**pixel by pixel**”.

Αυτού του είδους η ταξινόμηση συνήθως αναφέρεται ως **pixel-based Classification**.

Οι τεχνικές αντικειμενοστρεφούς ταξινόμησης (Object-oriented classification) επιτρέπουν στον αναλυτή να αποσυνθέσει την εικόνα σε πολλά σχετικά ομοιογενή αντικείμενα εικόνας, τα οποίες αναφέρονται ως patches ή segments, χρησιμοποιώντας μία διαδικασία κατάτμησης της εικόνας (image segmentation).

Τα διάφορα στατιστικά χαρακτηριστικά αυτών των αντικειμένων, στη συνέχεια διατίθενται στις διάφορες παραδοσιακές, στατιστικές ή και ασαφούς λογικής, μεθόδους ταξινόμησης.

Η αντικειμενοστρεφής ταξινόμηση βασίζεται στην κατάτμηση της εικόνας (segmentation) και έχει αρχίσει να χρησιμοποιείται συχνά στις μέρες μας στην ανάλυση εικόνων πολύ υψηλής χωρικής ανάλυσης για παράδειγμα στα συστήματα : 1×1 m Space Imaging IKONOS και 0.61×0.61 m Digital Globe QuickBird.

# Κεφάλαιο 7<sup>ο</sup>

## Υλοποίηση Αλγορίθμων

Σκοπός της παρούσας εργασίας , εκτός απο μία εκτενέστατη βιβλιογραφική ανάλυση σε θέματα υπερφασματικής απεικόνισης και κυρίως στην ταξινόμηση υπερφασματικών δεδομένων ήταν και η υλοποίηση κάποιων αλγορίθμων ταξινόμησης σε περιβάλλον matlab.

Για το σκοπό αυτό επιλέξαμε τους Supervised αλγορίθμους **Nearest Neighbour**, με κριτήριο πλησιότητα την ευκλείδεια απόσταση απ'τα φάσματα αναφοράς, και **Spectral Angle Mapper**, και τον Unsupervised αλγόριθμο **Euclidean Distance** , στην υλοποίηση του οποίου χρησιμοποιήσαμε και έναν learning rate παράγοντα λαμβάνοντας δηλαδή υπόψιν μας την πρόοδο της ταξινόμησης σε κάθε επανάληψη καθώς και τον αριθμό των επαναλήψεων .

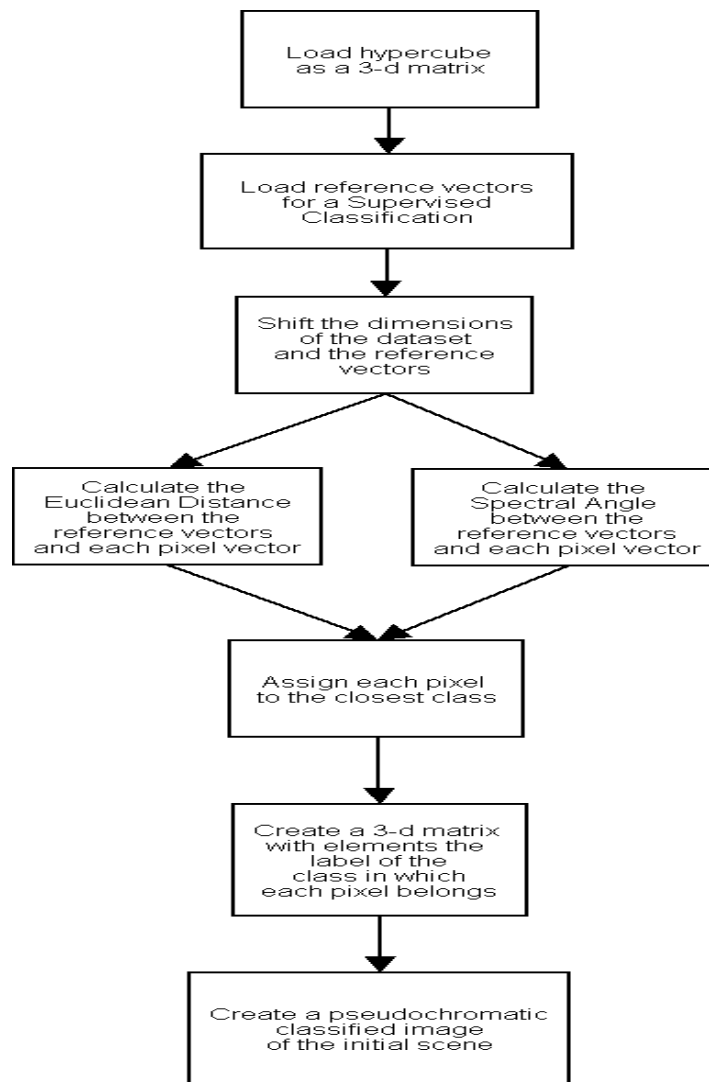
Για την επεξεργασία των δεδομένων χρησιμοποιήσαμε ολόκληρο τον αριθμό των ζωνών χωρίς να χρησιμοποιήσουμε τεχνικές data reduction και band selection

Για την επεξεργασία των δεδομένων τα θεωρήσαμε σαν τρισδιάστατους πίνακες **D [x,y,z]** με **x,y** τη χωρική πληροφορία για κάθε pixel, τη θέση δηλαδή του pixel στην εικόνα , και **z** τη φασματική.

Για μία εικόνα δηλαδή 820x820 σε 31 φασματικές ζώνες ο πίνακας με τις εντάσεις των pixels είναι **820x820x31** .

Οι αλγόριθμοι Nearest Neighbour και Spectral Angle Mapper υλοποιήθηκαν μέσω μιας κοινής βασικής ρουτίνας και το μόνο που αλλάζει ουσιαστικά είναι το κριτήριο πλησιότητας που στη μία περίπτωση είναι η ευκλείδεια απόσταση και στην άλλη η φασματική γωνία.

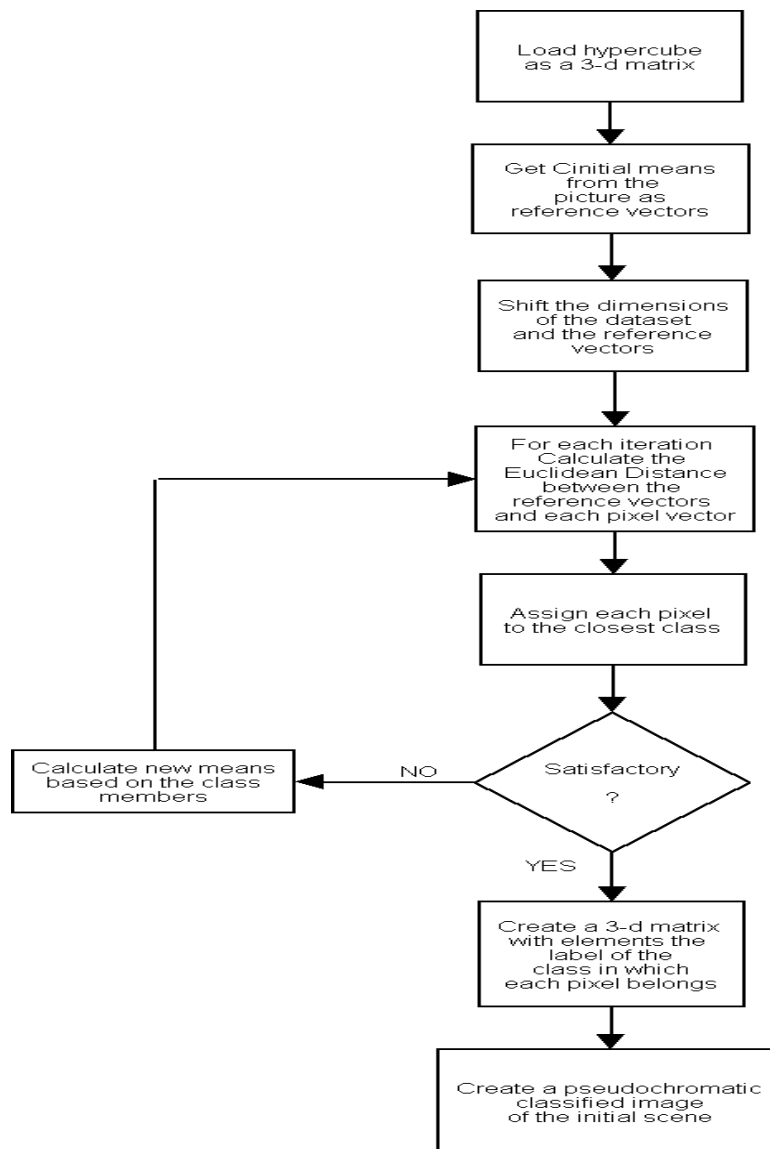
Η βασική ρουτίνα περιγράφεται απ'το παρακάτω διάγραμμα :



*Διαγρ . 15 Τα βήματα στη βασική ρουτίνα εκτέλεσης των Supervised αλγορίθμων Nearest Neighbour και Spectral Angle Mapper .*

Στην περίπτωση του Euclidean Distance τα πράγματα ήταν λίγο διαφορετικά μιας και όπως προαναφέραμε ο αλγόριθμος εκτελεί έναν αριθμό επαναλήψεων επαναπροσδιορίζοντας κάθε φορά τα καινούρια μέσα των τάξεων που έχει υπολογίσει.

Η διαδικασία εκτέλεσης φαίνεται στο παρακάτω διάγραμμα :



*Διαγρ . 16 Τα βήματα εκτέλεσης του επαναληπτικού Unsupervised αλγόριθμου Euclidean Distance .*

Η βασική διαφορά αυτής της ρουτίνας είναι η πρόσθεση ενός επαναληπτικού βρόχου μετά απο μια συνθήκη ελέγχου.

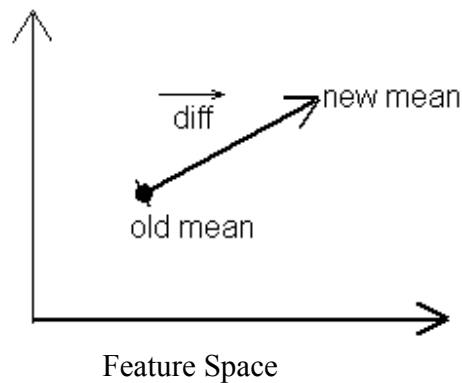
Ποια είναι αυτή η συνθήκη ελέγχου θα το δούμε αμέσως τώρα.

Έχουμε ήδη αναφέρει οτι ο αλγόριθμος επαναλαμβάνεται μέχρι να σταματήσουν να μετακινούνται τα pixels απο τη μία τάξη σε άλλη ή πολύ απλά όταν ολοκληρωθεί ένας προκαθορισμένος αριθμός επαναλήψεων. Έτσι όσο τίποτα απ'τα δύο δεν έχει συμβεί ο αλγόριθμος θα επαναλαμβάνει την ταξινόμηση σύμφωνα με τα νέα μέσα των τάξεων που έχει υπολογίσει.

Για να μπορέσουμε να εκμεταλλευτούμε την πρόοδο της ταξινόμησης σε κάθε επανάληψη με τρόπο τέτοιο ώστε να επιταχύνουμε την εκτέλεση του αλγορίθμου θα κάνουμε χρήση ενός ακόμα παράγοντα , τον οποίο θα ονομάσουμε **eta** .

Ο παράγοντας αυτός εξαρτάται και απ'τον αριθμό των αλλαγών που έχουν συμβεί στο σύνολο των pixels της εικόνας , αλλά και απ'τον αριθμό επαναλήψεων που έχουν συμβεί .

Για να κατανοήσουμε τη συνεισφορά του παράγοντα **eta** στη διαδικασία της ταξινόμησης ας φανταστούμε την αλλαγή του μέσου κατά τη διάρκεια μιας επανάληψης του αλγορίθμου ως εξής :



**Διαγρ . 17** Η αλλαγή του μέσου σε μία επανάληψη του αλγορίθμου

Στο τέλος κάθε επανάληψης ο αλγόριθμος αντικαθιστά το παλιό μέσο με αυτό που έχει υπολογίσει και το θέτει ως διάνυσμα αναφοράς (**reference vector**) για την επόμενη επανάληψη .

Η διαφορά τους είναι το διάνυσμα  $\vec{\text{diff}}$  .

Θα περιμέναμε να ισχύει :

$$\vec{\text{refvec}} = \vec{\text{oldmean}} + \vec{\text{diff}}$$

όπως φαίνεται και στην παραπάνω δισδιάστατη αναπαράσταση του χώρου χαρακτηριστικών για οποιεσδήποτε δύο φασματικές ζώνες .

Εδώ είναι και η συνεισφορά του παράγοντα **eta** στην βελτίωση του αλγορίθμου .  
Θέτω το νέο διάνυσμα αναφοράς ως :

$$\vec{\text{refvec}} = \vec{\text{oldmean}} + \text{eta} * \vec{\text{diff}}$$

δίνοντας έτσι μία ώθηση στο νέο διάνυσμα προς την κατεύθυνση που ούτως η άλλως έχει την τάση να πάει βελτιώνοντας έτσι το χρόνο εκτέλεσης του αλγορίθμου .

Αυτή η ώθηση δεν είναι τυχαία αλλά εξαρτάται απ'την **πρόοδο της ταξινόμησης** , τον αριθμό δηλαδή των αλλαγών που συμβαίνουν σε κάθε επανάληψη , και απ'τον **αριθμό των επαναλήψεων** που έχουν πραγματοποιηθεί .



Αυτή η εξάρτηση μπορεί να ελεγχθεί με τις παρακάτω εξισώσεις :

$$\text{eta} = \text{minEta} + ((\text{maxEta} - \text{minEta}) * \text{changes}) / (\text{X} * \text{Y}) \quad (1)$$

και

$$\text{eta} = \text{eta} * (1 - n / \text{zeroIter}) \quad (2) .$$

με  $X*Y$  το σύνολο των pixels στην εικόνα ,  $\text{changes}$  τον αριθμό των pixels που έχουν αλλάξει κατά τη διάρκεια της επανάληψης ,  $\text{zeroIter}$  τον αριθμό των επαναλήψεων που έχουμε ορίσει να εκτελεί ο αλγόριθμος,  $n$  τον αριθμός της τρέχουσας επανάληψης και  $\text{minEta} = 0.5$  και  $\text{maxEta} = 1.5$  , η ελάχιστη και μέγιστη τιμή αντίστοιχα , που μπορεί να πάρει ο παράγοντας  $\text{eta}$  .

Παρατηρούμε ότι μετά την πρώτη εκτέλεση του αλγορίθμου ο λόγος  $\text{changes}/X*Y$  θα ισούται με 1 , αφού όλα τα pixels θα έχουν αλλάξει , άρα ο  $\text{eta}$  παίρνει τη μέγιστη τιμή του ενισχύοντας έτσι την τάση του mean vector να κινηθεί προς την καινούργια του κατεύθυνση .

Μετά από έναν αριθμό επαναλήψεων , οι αλλαγές των pixels θα είναι λιγότερες οπότε ο παράγοντας κάποια στιγμή θα πάρει και τιμές μικρότερες της μονάδας επιβραδύνοντας ουσιαστικά την κίνηση του μέσου διανύσματος .

Θα εξηγήσουμε αμέσως γιατί συμβαίνει αυτό .

Η χρήση του παράγοντα  $\text{eta}$  σαν learning rate είναι πολύ σημαντική στην βελτίωση της εκτέλεσης του αλγορίθμου. Ωστόσο αν τροφοδοτηθεί με μεγάλες τιμές μπορεί να προκαλέσει σημαντική αστάθεια στην ταξινόμηση, όπως για παράδειγμα άπειρο αριθμό επαναλήψεων .

Ακόμα κι αν είχαμε θέσει ως όριο ένα προκαθορισμένο αριθμό επαναλήψεων, θα επιθυμούσαμε να σταματήσει η εκτέλεση κάποια στιγμή που η ταξινόμηση τουλάχιστον τείνει να σταθεροποιηθεί και κάποια στιγμή να σταματήσει .

Έτσι έχοντας μετά από έναν αριθμό επαναλήψεων το  $\text{eta} < 1$ , μπορεί να εξελίσσεται πιο αργά η ταξινόμηση, αποφεύγουμε όμως αυτές τις ανεπιθύμητες ταλαντώσεις .

## Κεφάλαιο 8<sup>ο</sup>


### *Αποτελέσματα*

Στη συνέχεια θα παραθέσουμε τα αποτελέσματα της ταξινόμησης και με τους τρεις αλγορίθμους , για διαφορετικούς αριθμούς τάξεων , σε έναν υπερφασματικό κύβο διαστάσεων **820 \* 820 \* 31** του οποίου τα στοιχεία είναι οι εντάσεις των pixels της παρακάτω εικόνας , σε 31 φασματικές ζώνες .




*Εικ . 30 Η RGB εικόνα της ταξινόμησης μας*


## 8.1 Ταξινόμηση για 5 τάξεις



*Εικ . A1* Αλγόριθμος *Nearest Neighbour*




*Εικ . A2* Αλγόριθμος *Spectral Angle Mapper*




*Εικ . Α3 Αλγόριθμος Euclidean Distance*


## 8.2 Ταξινόμηση για 9 τάξεις



*Εικ . A4 Αλγόριθμος Nearest Neighbour*




*Εικ . A5 Αλγόριθμος Spectral Angle Mapper*




*Εικ . A6 Αλγόριθμος Euclidean Distance*


**8.3 Ταξινόμηση για 12 τάξεις** . Λόγω του μεγάλου χρόνου εκτέλεσης των αλγορίθμων αναγκαστήκαμε για μεγάλο αριθμό τάξεων να δουλέψουμε σε ένα μικρότερο κομμάτι της εικόνας , **418x418 pixels** , κάτι που φυσικά δεν επηρέασε καθόλου την ταξινόμηση .



*Εικ . 7* Αλγόριθμος *Nearest Neighbour*




*Εικ . A8* Αλγόριθμος *Spectral Angle Mapper*




*Εικ . A9 Αλγόριθμος Euclidean Distance*


#### 8.4 Ταξινόμηση για 20 τάξεις



*Εικ . A10 Αλγόριθμος Nearest Neighbour*



*Εικ . Α11 Αλγόριθμος Spectral Angle Mapper*



*Εικ . Α12 Αλγόριθμος Euclidean Distance*



## 8.5 Κάποια συμπεράσματα για την ταξινόμηση

Ο πιο γρήγορος αλγόριθμος ήταν ο Nearest Neighbour . Ήταν όμως και ο χειρότερος στην ταξινόμηση , σε όλες σχεδόν τις περιπτώσεις εκτός απ'την πρώτη περίπτωση στην οποία είχαμε το μικρότερο αριθμό τάξεων , ίσο με 5 .

Ο Spectral Angle Mapper ήταν λίγο πιο αργός αλλά και ο πιο ακριβής ακόμα και απ'τον επαναληπτικό Euclidean Distance.

Ένα ενδιαφέρον σημείο είναι οτι ενώ θα περιμέναμε ο SAM αλγόριθμος να μην επηρεάζεται απ'τη φωτεινότητα της περιοχής, απ'το μήκος δηλαδή των διανυσμάτων και μόνο απ'την κατεύθυνσή τους , αυτό δεν έγινε παρα μόνο στην περίπτωση των 20 τάξεων , κάτι που μας προβλημάτισε για το αν ήταν επαρκής ο αριθμός των τάξεων και αν αυτό θα συνέχιζε να συμβαίνει και για μεγαλύτερο αριθμό τάξεων.

Ο αλγόριθμος Euclidean Distance ήταν παρ'όλες τις βελτιώσεις που του κάναμε αρκετά αργός (χρειάστηκε περίπου 40 λεπτά για την ταξινόμηση ολόκληρης της εικόνας στην περίπτωση των 9 τάξεων σε Pentium 4, 2.8 GHz) αλλά αρκετά ακριβής , περίπου όσο ακριβής ήταν και ο SAM .

Ο αριθμός επαναλήψεων που ορίσαμε στον Euclidean Distance ήταν ίσος με 30 και αυτό γιατί με μικρότερο αριθμό επαναλήψεων κατα το 90% των εκτελέσεων ο αλγόριθμος σταματούσε πριν να σταματήσουν να συμβαίνουν αλλαγές στα pixels. Αυτό μπορούσαμε να το δούμε ελέγχοντας την τιμή της παραμέτρου changes στο τέλος της εκτέλεσης.

Με τον αριθμό επαναλήψεων ίσο με 30 περίπου το 80 % των εκτελέσεων σταματούσε πριν να ολοκληρωθούν όλες οι επαναλήψεις.

Η επιλογή των τιμών του eta επίσης προέκυψε πειραματικά , και οι τιμές ανάμεσα στο 0.5 και 1.5 αποδείχθηκαν ιδανικές ώστε να μην έχουμε ταλαντώσεις απο άπειρες αλλαγές των pixels ειδικότερα για μεγάλο αριθμό τάξεων .

Ένα πολύ σημαντικό ζήτημα που προκύπτει είναι ο αριθμός των τάξεων που πρέπει να οριστεί. Παρατηρήσαμε ότι ο αλγόριθμος SAM άρχισε να μην επηρεάζεται απο τη διαφορετική φωτεινότητα μετά απ'την ταξινόμηση για 20 τάξεις.

Για μεγάλο αριθμό τάξεων όμως παρατηρήσαμε την εμφάνιση θορύβου στα όρια των τάξεων και μάλιστα με τη μορφή μιας επιπλέον τάξης.

Επιπλέον στην περίπτωση του Euclidean Distance ο θόρυβος αυτός μετακινούνταν συνεχώς απο τάξη σε τάξη παραμένοντας πάντα στην οριακή περιοχή μεταξύ των τάξεων που μετακινούνταν, κάτι που μας έδειχνε ξεκάθαρα ότι χρειαζόντουσαν λιγότερες τάξεις.

Ίσως αυτό δεν θα συνέβαινε αν επιτρέπαμε την ύπαρξη μη ταξινομημένων pixels , αλλά και πάλι το ότι τα μη ταξινομημένα pixels θα βρισκόντουσαν στις οριακές περιοχές μεταξύ των τάξεων δε θα ήταν ικανοποιητικό .

## Βιβλιογραφία

### Papers and Journals :

Peg Shippert, Ph.D , “Introduction to Hyperspectral Image Analysis”,Earth Science Applications Specialist Research Systems, Inc.

Robert P.W. Duin, Pavel Paclik, Serguei Verzakov , “Research challenges in spectral and spatial data analysis”,Pattern Recognition Group Delft University of Technology The Netherlands

Clark, R.N. “*Manual of Remote Sensing*”, A. Rencz, Editor, John Wiley and Sons, Inc. 1999

Clark, R.N. and T.L. Roush, “Reflectance Spectroscopy: Quantitative Analysis Techniques for Remote Sensing Applications”, *J. Geophys. Res.* 1984.

Robert P.W. Duin, “Pattern Recognition for Spectral Imaging”,Pattern Recognition Group ,Delft University of Technology,The Netherlands

4/4/2003 Pattern Recognition for Spectral Imaging 2

Pavel Paclik and Robert P.W Dwin,“Dissimilarity based classification of spectra : computational issues” Pattern Recognition Group Delft University of Technology The Netherlands

D.Landgrebe, “Hyperspectral image data analysis as a high dimensional signal processing problem.”,Special Issue of the IEEE Signal Processing Magazine , 19(1):17-28,January 2002

Clark, R.N., T.V.V. King, M. Klejwa, G.A. Swayze, and N. Vergo, 1990, “High Spectral Resolution Reflectance Spectroscopy of Minerals,” *Journal of Geophysical Research*, Vol. 95,

Vincent, R.K. (1997), “Fundamentals of Geological and Environmental Remote Sensing”, Prentice Hall, Upper Saddle River, New Jersey.

J. H. Lumme,”Classification of vegetation and soil using imaging spectrometer data”,Institute of Photogrammetry and Remote Sensing, Helsinki University of Technology, P.O.Box 1200, FIN-02015 HUT, Finland

Hannah Blau , Amy McGovern, “Categorizing Unsupervised Relational Learning Algorithms”, Department of Computer Science ,University of Massachusetts

Frank H. Wong, “Spectral Classification of images”,Department of computer Science University of British ColumbiaVancouver , B.C Canada, August 2003

Joachim M. Buhmann ,“Learning Issues in Image Segmentation”, Swiss Federal Institute of Technology (ETH Zurich), Institute for Computational Science, HRS-F31 8092 Zurich, Switzerland

Boardman, J. W. (1993), “Automated spectral unmixing of AVIRIS data using concept geometry concepts”, paper presented at Proceedings from the Airborne Geosciences Workshop.

Hord, R. M. (1982), “Digital Image Processing of Remotely Sensed Data”

Wilfredo Lugo – HP, Puerto Rico,Carmen Carvajal –UPRM,Wilson Rivera – UPRM “Hyperspectral classification and dimensionality reduction algorithms”, Gelato Federation Meeting,May 24-26, 2004

C. A. Shah, P. Watanachaturaporn, P. K. Varshney, “Some Recent Results on Hyperspectral Image Classification”, Dept. of Electrical Engineering and Computer Science Syracuse University, Syracuse, NY 13244, U.S.A. M. K. Arora  
Department of Civil Engineering I I T Roorkee, Roorkee 247667, India

Shailesh Kumar, Joydeep Ghosh, and Melba M. Crawford, Member, IEEE, “Best-Bases Feature Extraction Algorithms for Classification of Hyperspectral Data”

Belen Marti Cardona, “Accuracy Study of Agriculture Land Use Mapping Using AVIRIS Data”, ERS 186L. Spring 2003

M. Egmont-Petersena, D. de Ridderb, H. Handelsca, “Image processing with neural networks—a review” ,Institute of Information and Computing Sciences, Utrecht University, P.O.B. 80 089, 3508 TB Utrecht, Netherlands , Pattern Recognition Group, Department of Applied Physics, Delft University of Technology, Delft, Netherlands, Department of Medical Informatics, Lubeck Medical University, Lubeck, Germany,

Josef Cihlar<sup>1</sup>, Rasim Latifovic<sup>1</sup>, Jean Beaubien<sup>2</sup> , “A comparison of clustering strategies for unsupervised classification”,

1) Canada Centre for Remote Sensing, Ottawa, Canada 2) Canadian Forest Service, Ste-Foy, Quebec ,Submitted to:Canadian Journal of Remote Sensing Date: October 22, 1999,

J. Schwarz, and K. Staenz, “Adaptive Threshold for Spectral Matching of Hyperspectral Data” ,Canada Centre for Remote Sensing.

Chein-I Chang, Senior Member, IEEE, Hsuan Ren, Member, IEEE, and Shao-Shan Chiang, Student Member, IEEE , “Real-Time Processing Algorithms for Target Detection and Classification in Hyperspectral Imagery”.

Jason Hamel , “Simulation of Spectral Signatures”

Rasim Latifovic, Josef Cihlar, Jean Beaubien , “Clustering methods for unsupervised classification”, Intermap Technologies Ltd., Ottawa, Canada ,Canada Centre for Remote Sensing, Ottawa, Canada ,Canadian Forest Service, Canada.

Rachel E. Weber<sup>1</sup>, Ratna Naik<sup>\*1</sup>, Houbei Dai<sup>1</sup>, Neetu Shukla<sup>1</sup>, Gulay K. Serhatkulu<sup>2</sup>, Abhilash K. Pandya<sup>2</sup>, Jagdish Thakur<sup>2</sup>, D. Carl Freeman<sup>3</sup>, Alex Cao<sup>4</sup>, Raja Rabah<sup>4</sup>, Michael D. Klein<sup>4</sup>, Gregory W. Auner<sup>2</sup>, Vaman Naik<sup>5</sup>, Fred R. Miller<sup>6</sup> , “CLASSIFICATION OF RAMAN SPECTRA FOR TISSUE IDENTIFICATION”, Wayne State University, Department of Physics and Astronomy, Detroit, MI 482021, Wayne State University, Department of Electrical and Computer Engineering<sup>2</sup>, Wayne State University, Department of Biology<sup>3</sup>, Children’s Hospital of Michigan<sup>4</sup>, University of Michigan-Dearborn<sup>5</sup>, Karmanos Cancer Institute<sup>6</sup>.

Mark L. Chang Northwestern University Evanston, IL 60208 USA ,Scott A. Hauck  
University of Washington Seattle, WA 98195 USA “Adaptive Computing in NASA Multi-Spectral Image Processing” .

Erzsebet Merenyi , “The challenges in Spectral Image Analysis : an introduction and review of ANN Approaches”, University of Arizona , Lunar and Planetary Laboratory , PIRL Tucson, AZ 85721 , USA

S. Gürola, H. Öktema, T. Özalpa, B. Karasözen , “STATISTICAL LEARNING AND OPTIMIZATION METHODS FOR IMPROVING THE EFFICIENCY IN LANDSCAPE IMAGE CLUSTERING AND CLASSIFICATION PROBLEMS” METU, Institute of Applied Mathematics, 06531 Ankara, Turkey.

Rory Hutson, “Remote Sensing and Land Classification”, Remote Sensing Group Plymouth Marine Laboratory.

Wilfredo E. Lugo-Beauchamp, "PARALLELIZATION OF HYPERSPECTRAL IMAGING CLASSIFICATION AND DIMENSIONALITY REDUCTION ALGORITHMS", University of Puerto Rico Mayaguez Campus December 2004.

Richard B. Gomez and Ambrose J. Lewis, "On-BOARD PROCESSING FOR SPECTRAL REMOTE SENSING", Center for Earth Observing and Space Research  
George Mason University Fairfax, Va 22030, USA

Patrick J. Rauss, "Classification of Spectral Imagery Using Genetic Programming", U.S. Army Research Laboratory, Jason M. Daida Atmospheric, Oceanic and Space Sciences Dept. University of Michigan Shahbaz Chaudhary Atmospheric, Oceanic and Space Sciences Dept. University of Michigan

Robert P.W. Duin, Pavel Paclik, Serguei Verzakov "Hyperspectral image analysis"

Suresh Subramaniana, Nahum Gata, Michael Sheffield a, Jacob Barhenb, Nikzad Toomarian c, "Methodology for hyperspectral image classification using novel neural network", Opto-Knowledge Systems Inc. (OKSI), 4030 Spencer Street, Suite 108, Torrance, CA 90503-2442 bOak Ridge National Laboratory, Bethel Road, Bldg. 6010/214, Oak Ridge, TN 37831 cJet Propulsion Laboratory, 4800 Oak Grove Drive, Pasadena, CA 91109, George Lemeshevsky, "Interim Progress Report on the Application of an Independent Components Analysis-based Spectral Unmixing Algorithm to Beowulf Computers".

Ralph Root, Pablo Zarco-Tejada, Carlos Pinilla, Susan Ustin, Raymond Kokaly, Gerry Anderson, and Steve Hager, "Identification, Classification, and Mapping of Invasive Leafy Spurge Using Hyperion, AVIRIS, and CASI".

Marie-Louise O'Connell, a Tom Howley, b Alan G. Ryder, a Marc N. Leger, a Michael G. Madden. b, "Classification of a target analyte in solid mixtures using principal component analysis, support vector machines and Raman spectroscopy.", a Department of Chemistry/National Centre for Biomedical Engineering Sciences, National University of Ireland, Galway. b Department of Information Technology, National University of Ireland, Galway.

Machelle D. Wilson, Susan L. Ustin, Member IEEE, and David M. Rocke, "Classification of Contamination in Salt Marsh Plants Using Hyperspectral Reflectance".

I. Nedeljkovic, "IMAGE CLASSIFICATION BASED ON FUZZY LOGIC", MapSoft Ltd, Zahumska 26 11000 Belgrade, Serbia and Montenegro.

Bin Dai and Robert A. Lodder "Cholesterol, Elastin and Collagen Classification by Hyperspectral Integrated Computational Imaging", Department of Chemistry University of Kentucky.

Ali MOHAMMAD-DJAFARI, Nadia BALI and Adel MOHAMMADPOOR, "JOINT DIMENSIONALITY REDUCTION, CLASSIFICATION AND SEGMENTATION OF HYPERSPECTRAL IMAGES", Laboratoire des Signaux et Systèmes, Unité mixte de recherche 8506 (CNRS-Supélec-UPS) Supélec, Plateau de Moulon, 3 rue Joliot Curie, 91192 Gif-sur-Yvette, France.

Donghui Li, Mahmood R. Azimi-Sadjadi, and Marc Robinson, "Comparison of Different Classification Algorithms for Underwater Target Discrimination".

S. J. Purkis Z R. Pasterkamp, "Integrating in situ reef-top reflectance spectra with Landsat TM imagery to aid shallow-tropical benthic habitat mapping".

Joseph P. Hoffbeck and David A. Landgrebe, "Classification of High Dimensional Multispectral Image Data", School of Electrical Engineering Purdue University West Lafayette, IN 47907.

David Landgrebe, "Some Fundamentals and Methods for Hyperspectral Image Data Analysis", School of Electrical & Computer Engineering Purdue University, West Lafayette.

Dr Giuliana Profeti , “Fundamentals of remote sensing image processing”

Shirley Morillo Contreras , “A COMPARISON OF RESOLUTION ENHANCEMENT METHODS AS PRE-PROCESSING FOR CLASSIFICATION OF HYPERSPECTRAL IMAGES” ,Department of Electrical and Computer Engineering University of Puerto Rico 2004

Lindsay I Smith , “A tutorial on Principal Components Analysis” , February 26, 2002

David Landgrebe , “Hyperspectral Image Data Analysis as a High Dimensional Signal Processing Problem”,School of Electrical & Computer Engineering Purdue University West Lafayette .

**Web Sites:**

- United States Geological Survey Spectroscopy Lab.  
<http://speclab.cr.usgs.gov>
- The Remote Sensing Tutorial , NASA  
<http://rst.gsfc.nasa.gov/HOMEPAGE/Homepage.html>
- Earth Observation Magazine  
<http://www.eomonline.com/index.php>
- Earth Sciences Information Centre  
<http://ess.nrcan.gc.ca/esic/index.php>