


## Επεξεργασία & Ανάλυση Βιοϊατρικών Εικόνων


Περιγραφείς Εικόνων & Αναγνώριση Προτύπων

Δρ. Δημήτρης Ιακωβίδης

Κατανόηση Περιεχομένου Εικόνων



## Κατανόηση περιεχομένου εικόνων



## Πως ξεχωρίζουμε τα αντικείμενα;

### • Χρώμα (color)

- Το σπίτι είναι κόκκινο
- Το γρασίδι είναι πράσινο
- Τα δέντρα είναι πράσινα
- Ο φράχτης είναι καφέ
- Ο ουρανός είναι μπλε
- Τα σύννεφα είναι άσπρα
- Η λίμνη είναι περισσότερο μπλε αλλά μοιράζεται και άλλα χρώματα από το περιβάλλον



## Πως ξεχωρίζουμε τα αντικείμενα;

- **Υφή (texture)**

- Αναφέρεται στο πως κατανέμονται οι αποχρώσεις ενός αντικειμένου στο χώρο (στο επίπεδο της εικόνας).
- Αν δύο αντικείμενα έχουν το ίδιο χρώμα μπορούμε να τα ξεχωρίσουμε από την υφή τους!
  - Τα δέντρα έχουν χονδροειδή (coarse) υφή και το γρασίδι λεπτή (fine).
  - Η λίμνη επειδή το νερό κινείται είναι λιγότερο ομοιόμορφη (uniform) από τον ουρανό.



## Πως ξεχωρίζουμε τα αντικείμενα;

- **Σχήμα (shape)**

- Τα αντικείμενα που έχει κατασκευάσει ο άνθρωπος χαρακτηρίζονται συνήθως από έντονες γωνίες.
- Ο φράχτης χαρακτηρίζεται από παράλληλες γραμμές
- Το σπίτι έχει πολυγωνικό σχήμα



## Ποσοτικοποίηση της εικόνας

- Πρέπει να μετατρέψουμε το περιεχόμενο της εικόνας σε αριθμούς προκειμένου να γίνει κατανοητό από τις μηχανές.
- Ίδανικά κάθε διαφορετικό αντικείμενο θα πρέπει να περιγράφεται με ένα δικό του σύνολο αριθμητικών τιμών.
- Κάθε μια από τις τιμές αυτές είναι περιγράφει ένα **χαρακτηριστικό (feature) / ιδιότητα (attribute)** του αντικειμένου
- Όλες μαζί οι τιμές αυτές συνιστούν ένα διάνυσμα **χαρακτηριστικών (feature vector)** που περιγράφει το αντικείμενο, δηλαδή είναι ένας **περιγραφέας (descriptor) ή υπογραφή (signature)**.

## Ποσοτικοποίηση της εικόνας



(0.2, 0.5, ...) χρώμα  
(0.8, 0.2, ...) υφή

Ο ουρανός έχει χρώμα και υφή αλλά δεν έχει σχήμα.

(0.2, 0.5, ...) χρώμα  
(0.8, 0.2, ...) υφή  
(0.1, 0.3, ...) σχήμα

περιγραφέας ← (0.8, 0.2, ...) υφή  
(0.1, 0.3, ...) σχήμα  
χαρακτηριστικό

Το στίπτι έχει και σχήμα !

## Επισημείωση της εικόνας



- Για να υποδείξουμε στο σύστημα που βρίσκεται κάθε αντικείμενο χρειάζεται επισημείωση.
  - Παράδειγμα: Σπίτι

- Η επισημείωση εξυπηρετεί 2 σκοπούς:

- Εκπαίδευση του συστήματος (αν είναι καθοδηγούμενο)
- Αξιολόγηση της απόδοσης του συστήματος.




## Ερώτηση 1

- Το περιεχόμενο της εικόνας δεν είναι αριθμοί; Γιατί δε χρησιμοποιούμε απευθείας τις τιμές των εικονοστοιχείων;
- Απάντηση
  - Μια περιοχή της εικόνας έχει πάρα πολλά εικονοστοιχεία.
  - Υπάρχει πολύ πληροφορία, δύσκολα όμως ερμηνεύεται.
  - Η εξαγωγή (υπολογισμός) χαρακτηριστικών ισοδυναμεί
    - με αφαίρεση περιττής πληροφορίας (μείωση πολυπλοκότητας του προβλήματος).
    - με εξόρυξη πληροφορίας αναφορικά με συγκεκριμένες ιδιότητες που μπορεί να έχει μια περιοχή της εικόνας.

## Ορθογωνιότητα

- Το χρώμα, η υφή και το σχήμα είναι μεταξύ τους ασυσχετίστες ιδιότητες και η μία συμπληρώνει την άλλη.
  - π.χ. δεν είναι επιθυμητό ένα χαρακτηριστικό υφής να εξαρτάται από τις αποχρώσεις της εικόνας.




## Ερώτηση 2

- Πως επιλέγονται οι περιοχές από όπου θα εξαγάγουμε τα χαρακτηριστικά;
- Απάντηση
  - Από ολόκληρες τις εικόνες.
  - Δειγματοληψία χειροκίνητα, συνήθως από ειδικό.
  - Δειγματοληπώντας ολόκληρη την εικόνα ομοιόμορφα χρησιμοποιώντας ένα τετράγωνο παράθυρο.
  - Δειγματοληπώντας την εικόνα τυχαία.
  - Δειγματοληψία από τμήματα της εικόνας, όπως προκύπτουν από τμηματοποίησή της (segmentation)
  - Δειγματοληψία από σημεία ενδιαφέροντος που εντοπίζονται αυτόματα.


## Δειγματοληψία σταθερού ρυθμού

Βήμα ολίσθησης




- Το βήμα ολίσθησης επιλέγεται μικρότερο ή ίσο του μεγέθους του παραθύρου.
- Το μέγεθος του παραθύρου επιλέγεται συνήθως εμπειρικά βάσει το μεγέθους των αντικειμένων που επιθυμούμε να εντοπίζουμε.

## Τυχαία δειγματοληψία



- Την επιλέγουμε συνήθως όταν επιθυμούμε να κατασκευάσουμε ένα σύνολο διανυσμάτων εκπαίδευσης για ένα αλγόριθμο μηχανικής μάθησης, ώστε η επιλογή τους να είναι όσο το δυνατόν αμερόληπτη.

## Δειγματοληψία από τμήματα εικόνας



Δείγματα

Τμήμα

- Την επιλέγουμε συνήθως όταν μας ενδιαφέρει να αναλύσουμε μια συγκεκριμένη περιοχή της εικόνας.
- Η τμηματοποίηση μπορεί να γίνεται είτε χειροκίνητα (επισημείωση), είτε αυτόματα με αλγόριθμο.

(Iakovidis et al, 2009)

## Δειγματοληψία από τμήματα εικόνας



Εξαγωγή  
χαρακτηριστικών  
από κάθε τμήμα  
(superpixel)

Superpixel segmentation

- Το πλεονέκτημα αυτής της μεθόδου είναι ότι η εξαγωγή χαρακτηριστικών γίνεται από ομοιογενείς περιοχές που πιθανώς περιλαμβάνουν εικονοστοιχεία μόνο ενός αντικειμένου.

(Iakovidis et al, 2015; Achanti et al, 2012)




## Δειγματοληψία από σημεία ενδιαφέροντος

- Ως σημεία ενδιαφέροντος προσδιορίζονται σημεία της εικόνας που φέρουν ιδιαίτερη πληροφορία.
- Τυπικά ως σημείο ενδιαφέροντος ορίζεται ένα σημείο της εικόνας στο οποίο το σήμα αλλάζει σε δύο διαστάσεις, π.χ.
  - Γωνίες, διασταυρώσεις Y και T
  - Μαύρες κουκκίδες σε λευκό υπόβαθρο
  - Οι απολήξεις διακλαδώσεων
  - Οποιαδήποτε περιοχή με έντονη υφή
- Ωστόσο σημεία ενδιαφέροντος θα μπορούσαν να ορίζονται αναλόγως της εφαρμογής, π.χ. κόκκινα σημεία αν αναζητούμε περιοχές με ερυθρότητα, όπως είναι το αίμα.

## Εντοπισμός σημείων ενδιαφέροντος


### Παράδειγμα



“επίπεδη”

περιοχή:


καμιά αλλαγή σε  
όλες τις  
κατευθύνσεις



“ακμή”:

καμιά αλλαγή στην

κατεύθυνση της  
ακμής



“γωνία”:

σημαντική αλλαγή

προς όλες τις  
κατευθύνσεις

## Εντοπισμός σημείων ενδιαφέροντος

Εντοπισμός γωνιών με τη μέθοδο Harris

- Σε κάθε σημείο  $x(x,y)$  της εικόνας υπολογίζουμε:

$$C(x, \sigma, \tilde{\sigma}) = G(x, \tilde{\sigma}) * \begin{bmatrix} I_x^2(x, \sigma) & I_x I_y(x, \sigma) \\ I_x I_y(x, \sigma) & I_y^2(x, \sigma) \end{bmatrix}$$



$$I_x \Leftrightarrow \frac{\partial I}{\partial x}$$

$$I_y \Leftrightarrow \frac{\partial I}{\partial y}$$

$$I_x I_y \Leftrightarrow \frac{\partial I}{\partial x} \frac{\partial I}{\partial y}$$

$I_x(x, \sigma)$  είναι η συνέλιξη της εικόνας  $I$  με τη μερική παράγωγο ως προς  $x$  Γκαουσιανής που έχει τυπική απόκλιση  $\sigma$ , ομοίως οι υπόλοιπες.

Η  $I_x^2$  και οι υπόλοιπες, συνελίσσονται απευθείας με τη  $G(x, \tilde{\sigma})$

(Harris & Stephens, 1988)

## Γκαουσιανές μάσκες και παράγωγοι

Οι γκαουσιανές μάσκες και οι μερικές παράγωγοί τους με τις οποίες συνελίσσονται οι εικόνες προκύπτουν ως εξής:

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

$$G_x = \frac{\partial G(x, y, \sigma)}{\partial x} = -\frac{x}{2\pi\sigma^4} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

$$G_{xx} = \frac{\partial^2 G(x, y, \sigma)}{\partial x^2} = \left(-1 + \frac{x^2}{\sigma^2}\right) \frac{e^{-\frac{x^2+y^2}{2\sigma^2}}}{2\pi\sigma^4}$$

$$G_{yy} = \frac{\partial^2 G(x, y, \sigma)}{\partial y^2} = \left(-1 + \frac{y^2}{\sigma^2}\right) \frac{e^{-\frac{x^2+y^2}{2\sigma^2}}}{2\pi\sigma^4}$$

$$G_{xy} = \frac{\partial^2 G(x, y, \sigma)}{\partial x \partial y} = \frac{xy}{2\pi\sigma^6} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

## Εντοπισμός σημείων ενδιαφέροντος

Εντοπισμός γωνιών με τη μέθοδο Harris

- Έχοντας τις τιμές του  $C$  για κάθε σημείο της εικόνας, ελέγχεται αν

$$\det(C) - \alpha \text{trace}^2(C) > t$$

όπου

- $\text{trace}$  το ίχνος του πίνακα, δηλ το άθροισμα των διαγώνιων στοιχείων του
- $\det$  η ορίζουσα του πίνακα
- $\alpha$  μια σταθερά συνήθως στο διάστημα 0.04-0.06
- $t$  μια τιμή κατωφλίου η οποία καθορίζει πόσα σημεία θα επιλεχθούν.


(Harris & Stephens, 1988)

## Εντοπισμός σημείων ενδιαφέροντος

Παράδειγμα εντοπισμού γωνιών με τη μέθοδο Harris



Κόκκινο: υψηλές τιμές  
Μπλε: χαμηλές τιμές



(Harris & Stephens, 1988)

## Εντοπισμός σημείων ενδιαφέροντος

Εντοπισμός σημείων ενδιαφέροντος με τη μέθοδο του πίνακα Hessian

$$H(x, \sigma) = \begin{bmatrix} I_{xx}(x, \sigma) & I_{xy}(x, \sigma) \\ I_{xy}(x, \sigma) & I_{yy}(x, \sigma) \end{bmatrix}.$$


όπου

- $I_{xx}$  η δεύτερη μερική παράγωγος (second gradient) της εικόνας η οποία λαμβάνεται με συνέλιξη της εικόνας  $I$  με τη δεύτερη μερική παράγωγο της Γκαουσιανής.

(Beaudet, 1978)

## Αυτόματος διαχωρισμός διανυσμάτων

- Συσταδοποίηση (clustering),
  - Μη καθοδηγούμενη (unsupervised)
  - Ανέυρεση παρόμοιων διανυσμάτων χωρίς εκπαίδευση
  - Συστάδες με σημασιολογική αξία (ιδανικά)
  - Παραδείγματα: k-means, FCM, NMF (βλ. data mining)



## Συσταδοποίηση $k$ -Means

- Ομαδοποιεί διανύσματα σε συστάδες (κλάσεις) με στόχο την ελαχιστοποίηση μιας αντικειμενικής συνάρτησης  $J$

$$J = \sum_{k=1}^K \sum_{x_i \in C_k} d(x_i, \mu_k)^2$$

- Ο χρήστης παρέχει στον αλγόριθμο των  $K$ -Μέσων
  - Τα διανύσματα εισόδου
  - Το πλήθος  $K$  των συστάδων στο οποίο επιθυμεί να καταλήξει
  - Ποια διανύσματα να θεωρηθούν αρχικά κέντρα των συστάδων

(Jain, 2009; MacQueen, 1967)


## Συσταδοποίηση $k$ -Means

- Βήμα 1
  - Δίδεται ένα σύνολο σημείων (διανυσμάτων) εισόδου
  - Ο χρήστης θέλει να οργανώσει τα σημεία π.χ. σε  $K = 3$  συστάδες
  - Αρχικά επιλέγουμε τυχαία  $K$  διανύσματα τα οποία θεωρούμε ως κέντρα των  $K$  συστάδων



## Συσταδοποίηση $k$ -Means

- Βήμα 2
  - Υπολογίζονται οι αποστάσεις όλων των σημείων από όλα τα κέντρα
  - Για κάθε σημείο προσδιορίζεται το κοντινότερο κέντρο του
  - Κάθε σημείο ανατίθεται στην συστάδα που αντιστοιχεί στο κοντινότερο κέντρο (κάθε σημείο έχει ένα κοντινότερο κέντρο)



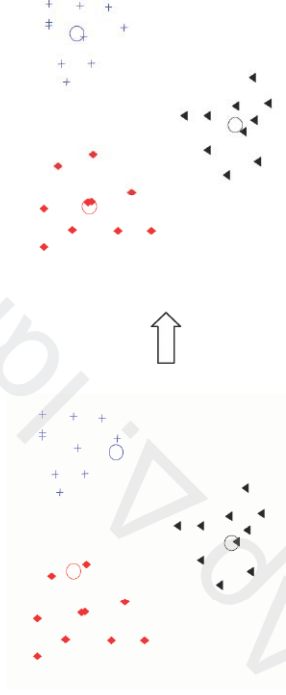
## Συσταδοποίηση $k$ -Means

- Βήμα 3
  - Για το σύνολο των σημείων που ανήκουν τώρα σε μια συστάδα υπολογίζεται το νέο κέντρο της συστάδας
  - Επαναλαμβάνεται το ίδιο για όλες τις συστάδες




## Συσταδοποίηση $k$ -Means

- Βήμα 4
  - Επανελάβε τα βήματα 2 και 3 μέχρι να μην αλλάζουν τα κέντρα από επανάληψη σε επανάληψη




## Αυτόματος διαχωρισμός διανυσμάτων

- Ταξινόμηση σε κλάσεις (classification)
  - Καθοδηγούμενη (supervised)
  - Διαχωρισμός των διανυσμάτων.
  - Κάθε κλάση αναπαριστά σημειολογικά μια οντότητα.
  - Παραδείγματα:  $k$ -NN, νευρωνικά δίκτυα, SVM κ.α. (βλ. data mining)



## Ταξινόμηση κοντινότερων γειτόνων k-Nearest Neighbors k-NN

- Έστω πως είναι γνωστή η κλάση στην οποία ανήκουν  $N$  δείγματα (ανύσματα χαρακτηριστικών)
- Έστω ένα νέο δείγμα  $x$  το οποίο επιθυμούμε να ταξινομηθεί
- Υπολογίζουμε τις αποστάσεις του  $x$  από όλα τα υπόλοιπα  $N$  δείγματα
- Το  $x$  θα ταξινομηθεί στην κλάση  $\omega_j$  αν η πλειοψηφία των  $k$  κοντινότερων γειτόνων του  $x$  ανήκουν στην κλάση  $\omega_j$



## Ταξινόμηση κοντινότερων γειτόνων k-Nearest Neighbors k-NN

- Στην περίπτωση ταξινόμησης σε 2 κλάσεις, ποια είναι η πιθανότητα να ανήκει το  $x$  στην κλάση  $\omega_j$ ;

$$y = \frac{1}{k} \sum_{i=1}^k y_i$$

όπου  $y_i$  η ετικέτα που φανερώνει την κλάση  $\omega_j$  που ανήκει κάθε κοντινότερος γείτονας  $x_i$

- Παράδειγμα
  - Αν  $k=3$ , ο ένας γείτονας του  $x$  ανήκει στην κλάση 0 και οι άλλοι δύο στην κλάση 1
  - Τότε το  $x$  ανήκει στην κλάση 0 με πιθανότητα  $1/3=33.3\%$  και στην κλάση 1 με πιθανότητα  $2/3 = 66.7\%$ , άρα στην 1 (μέγιστη)



## Αξιολόγηση της ταξινόμησης

Πίνακας ταξινόμησης (confusion matrix)	Εντοπιστήκαν /	Ταξινομήθηκαν
	Θετικά	Αρνητικά
	<i>a</i>	<i>b</i>

Θετικά	<i>true</i>	<i>false</i>
Αρνητικά	<i>positive</i>	<i>negative</i>
	<i>c</i>	<i>d</i>
Πραγματικά	<i>true</i>	<i>false</i>
	<i>positive</i>	<i>negative</i>

$$\text{Ακρίβεια (Accuracy)} = \frac{a+d}{a+b+c+d} = 1 - \text{Σφάλμα (Error)}$$

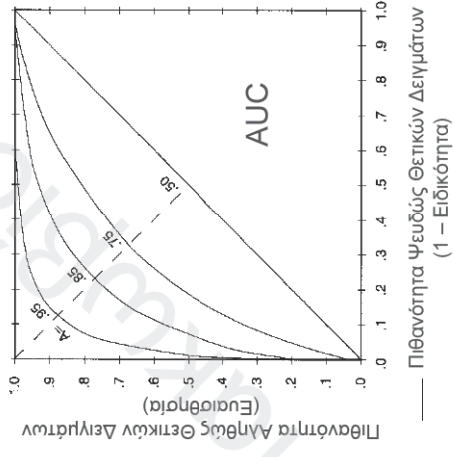
$$\text{Ευσαιθησία (Sensitivity)} = \text{TPR} = \frac{a}{a+b}$$

$$\text{Ειδικότητα (Specificity)} = 1 - \text{FPR} = \left(1 - \frac{c}{c+d}\right)$$

Μόνο για  
δύο  
κλάσεις...

## Αξιολόγηση της ταξινόμησης

- Η καμπύλη ROC (Receiver Operating Characteristic) παρουσιάζει το ισοζύγιο του TPR προς το FPR
- Υπολογίζεται μεταβάλλοντας την τιμή του κατωφλίου στην πιθανότητα ταξινόμησης που παράγει ο ταξινομητής
- Το **εμβαδόν κάτω από τη ROC** (Area Under Curve, AUC) μονόμετρο αντιπροσωπευτικό μέτρο της ακρίβειας της ταξινόμησης
- Ανεξάρτητο της κατανομής των δειγμάτων στις κλάσεις!




(Bradley, 1997; Swets et al., 2000)

## Χρώμα και υφή

- Στο χώρο RGB υφή υπάρχει σε κάθε κανάλι
  - Ωστόσο στη βιβλιογραφία περιγράφονται προσεγγίσεις που εξάγουν χαρακτηριστικά υφής από κάθε κανάλι του RGB (δεν προτείνεται)
- Προτείνεται η χρήση ορθογώνιων χρωματικών χώρων για την εξαγωγή της πληροφορίας υφής ξεχωριστά από την πληροφορία χρώματος.
  - Διηλαδή χρωματικοί χώροι με ασυσχέτιστα κανάλια αντί για τον RGB.
- Παραδείγματα
  - HSV → Χρώμα από (H,S) και υφή από V.
  - CIE-Lab → Χρώμα από (a,b) και υφή από L.
  - $I_1I_2I_3$  → Χρώμα από ( $I_2, I_3$ ) και υφή από  $I_1$ .
  - YIQ, YUV, YCbCr κοκ → Υφή από Y και χρώμα από τα άλλα κανάλια

(Maerbaa & Pietikainen, 2004)

## Χρώμα και υφή



Τι περιμένετε να δείτε στο HSV;...


## Παράδειγμα HSV



Απόχρωση (Hue)

## Παράδειγμα HSV


Δεν ορίζεται hue για το άσπρο.  
Αν όμως βάλεις 0 τότε δεν  
ξεχωρίζεται από το κόκκινο !!!



Απόχρωση (Hue)

## Παράδειγμα HSV

- Γιατί δεν ορίζεται το Hue για το λευκό;
  - Θυμηθείτε τον ορισμό του



$$H = \frac{1}{6} * \begin{cases} \frac{G - B}{C} \text{ mod } 6 & \text{if } \max(R, G, B) = R \\ \frac{B - R}{C} + 2 & \text{if } \max(R, G, B) = G \\ \frac{R - G}{C} + 4 & \text{if } \max(R, G, B) = B \end{cases}$$

$$C = \max(R, G, B) - \min(R, G, B).$$

Για το άσπρο  $C \approx 0$

## Παράδειγμα HSV

Τα σύννεφα δεν έχουν χρώμα άρα εντοπίζονται για  $S \approx 0$



Κορεσμός (Saturation)


## Παράδειγμα HSV

Η υφή των δέντρων ξεχωρίζει από εκείνη του γρασιδιού



Φωτεινότητα (Value)

## Παράδειγμα CIE-Lab








Γιατί είναι προτιμότερο το CIE-Lab;







Το CIE-Lab δεν παρουσιάζει ασυνέχειες !!!

Πως διαχωρίζουμε αντικείμενα διαφορετικού χρώματος;



## Πως διαχωρίζουμε αντικείμενα διαφορετικού χρώματος;



## Ιστόγραμμα

- Το ιστόγραμμα μιας περιοχής περιγράφει πόσες φορές εμφανίζεται μια απόχρωση στην περιοχή αυτή.
- Το ιστόγραμμα μιας περιοχής περιέχει πληροφορία για το περιεχόμενο της ως προς το χρώμα
  - Ένα ιστόγραμμα μιας περιοχής της εικόνας μπορεί να θεωρηθεί ως περιγραφέας
- Αν χρησιμοποιούμε δυο ή τρία χρωματικά κανάλια τότε ποιο ιστόγραμμα;
  - Ένα διάγραμμα με τα δύο ιστογράμματα συνενωμένα.
  - Ένα διδιάστατο ή ένα τρισδιάστατο ιστόγραμμα.

## Ιστόγραμμα αποχρώσεων ενός χρωματικού καναλιού

```
histogram[] ← 0;  
for i = 1 to rows  
{  
  for j = 1 to columns  
  {  
    histogram[channel[i][j]] =  
      histogram[channel[i][j]] + 1  
  }  
}
```

- Δηλαδή, καθώς σαρώνεται η εικόνα κάθε φορά που συναντάται μια απόχρωση αυξάνει κατά ένα η τιμή της αντίστοιχης θέσης του πίνακα που περιέχει το ιστόγραμμα.
- Αν η εικόνα δεν είναι έγχρωμη τότε θεωρείται ότι έχει μόνο ένα κανάλι, αυτό της έντασης των αποχρώσεων του γκριζου.

## Διδιάστατο ιστόγραμμα αποχρώσεων δύο χρωματικών καναλιών

```
histogram[][] ← 0;  
for i = 1 to rows  
{  
  for j = 1 to columns  
  {  
    histogram[channel1[i][j]][channel2[i][j]] =  
      histogram[channel1[i][j]][channel2[i][j]] + 1  
    }  
}
```

- Δηλαδή, καθώς σαρώνεται η εικόνα κάθε φορά που συναντάται ένα ζεύγος αποχρώσεων αυξάνει κατά ένα η τιμή της αντίστοιχης θέσης του διδιάστατου πίνακα που περιέχει το ιστόγραμμα.




## Κατανομή πιθανοτήτων από ιστόγραμμα

- Συμφέρει να κανονικοποιούμε το ιστόγραμμα διαιρώντας δια το πλήθος των εικονοστοιχείων της περιοχής.
- Η κανονικοποίηση έχει ως αποτέλεσμα οι τιμές του ιστογράμματος:
  - Να είναι σε συγκεκριμένο διάστημα  $[0, 1]$  ανεξάρτητα από το μέγεθος της περιοχής από την οποία υπολογίζεται.
  - Να αναπαριστούν πιθανότητες εμφάνισης αποχρώσεων.

## Ομοιόμορφη κβάντιση αποχρώσεων και ιστόγραμμα

Για τη μείωση της διάστασης του ιστογράμματος εφαρμόζεται συνήθως η ομοιόμορφη κβάντιση των αποχρώσεων της εικόνας.




256 αποχρώσεις


4 αποχρώσεις

## Ομοιόμορφη κβάντιση αποχρώσεων και ιστόγραμμα

Παράδειγμα εικόνας που έχει υποστεί κβάντιση αποχρώσεων



256 αποχρώσεις



4 αποχρώσεις

## Ομοιόμορφη κβάντιση αποχρώσεων και ιστόγραμμα

• Πως υλοποιείται;

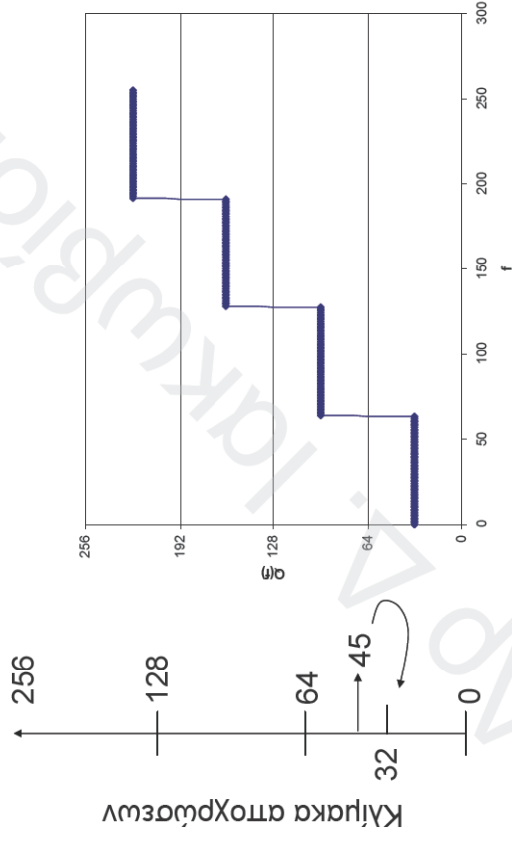
- Αν οι αποχρώσεις συμβολίζονται με  $f$  και  $q$  είναι το βήμα ανάμεσα στις αποχρώσεις, τότε οι νέες, κβαντισμένες αποχρώσεις της εικόνας υπολογίζονται ως εξής:

$$Q(f) = \left\lfloor \left[ \frac{f - f_{\min}}{q} * q + \frac{q}{2} + f_{\min} \right] \right\rfloor$$

→ Στάθμη


- Όπου  $f_{\min}$  η ελάχιστη και  $f_{\max}$  η μέγιστη δυνατή απόχρωση, π.χ. για εικόνες 8bit/κανάλι  $f_{\min} = 0$  και  $f_{\max} = 255$ .
- Το βήμα  $q = (f_{\max} - f_{\min} + 1) / L$  όπου του  $L$  είναι το επιθυμητό πλήθος των σταθμών κβάντισης, δηλ. για  $L=4$  το  $q=64$ .

## Ομοίомορφη κβάντιση αποχρώσεων και ιστόγραμμα



## Κεντρικές ροπές


Η πληροφορία του ιστογράμματος μιας περιοχής μπορεί να προσεγγιστεί και με κεντρικές στατιστικές ροπές.



$$\mu = \bar{x} = \frac{1}{N} \sum_{j=1}^N x_j \quad \sigma(x_1 \dots x_N) = \sqrt{\text{Var}(x_1 \dots x_N)}$$

$$\text{Var}(x_1 \dots x_N) = \frac{1}{N-1} \sum_{j=1}^N (x_j - \bar{x})^2$$

## Κεντρικές ροπές




$$\text{Skew}(x_1 \dots x_N) = \frac{1}{N} \sum_{j=1}^N \left[ \frac{x_j - \bar{x}}{\sigma} \right]^3$$

$$\text{Kurt}(x_1 \dots x_N) = \left\{ \frac{1}{N} \sum_{j=1}^N \left[ \frac{x_j - \bar{x}}{\sigma} \right]^4 \right\} - 3$$

## Εφαρμογές


- Παράδειγμα 1

- Εντοπισμός περιοχών με αίμα σε ενδοσκοπικές εικόνες.
- Τμηματοποίηση superpixel
- Χαρακτηριστικά η μέση τιμή και η τυπική απόκλιση του καναλιού a του CIE-Lab και μέση τιμή του κορεσμού (S) από τον HSV.
- Υβριδικός χρωματικός χώρος!
- Ευαισθησία / ειδικότητα 96% / 91%



(Iakovidis et al, 2015; Achanti et al, 2012)

## Εφαρμογές




### Παράδειγμα 2


- Εντοπισμός πολλαπλών αλλοιώσεων
- 1370 εικόνες (252 ασθενείς)
- 10 κλάσεις

(Iakovidis & Koulaouzidis, 2014)

## Εφαρμογές




### Εικόνα εισόδου



### Μετασχηματισμός σε CIE-Lab

(Iakovidis & Koulaouzidis, 2014)

## Εφαρμογές




### Σημαντικό εύρημα !

1. Τουλάχιστον ένα σημείο ενδιαφέροντος εντοπίστηκε σε κάθε αλλοίωση.
2. Εντοπισμός πολύ μικρών αλλοιώσεων.

Σημεία ενδιαφέροντος εντοπισμένα με τη χρήση του πίνακα Hessian στο κανάλι a

(Iakovidis & Koulaouzidis, 2014)


## Εφαρμογές



Χαρακτηριστικά: Τιμές L, a, b των εικονοστοιχείων από τα σημεία ενδιαφέροντος και μέγιστες-ελάχιστες τιμές των L, a, b στην περιοχή

(Iakovidis & Koulaouzidis, 2014)

## Εφαρμογές




SVM Classification


(Iakovidis & Koulaouzidis, 2014)

## Εφαρμογές

- Χαρακτηριστικά έντασης χρησιμοποιούνται σε ιατρικές εικόνες των οπείων η ένταση των αποχρώσεων είναι εξορισμού διαφορετική για τους απεικονιζόμενους ιστούς.
- Σχετικά παραδείγματα



Μαγνητική Τ.



Αξονική Τ.



Υπέρηχος



Ακτινογραφία





## Άσκηση

- Να χρησιμοποιήσετε το ιστόγραμμα για την εύρεση του κυρίαρχου χρώματος μιας περιοχής εικόνας.

## Άσκηση

- Να χρησιμοποιήσετε το ιστόγραμμα για την εύρεση του κυρίαρχου χρώματος μιας περιοχής εικόνας.
- Απάντηση
  - Βρίσκοντας την αποχρωση με τη μέγιστη τιμή / πλήθος εμφανίσεων.
  - Αν επιθυμούμε να βρούμε τις  $N$  συχνότερα εμφανιζόμενες αποχρώσεις, ταξινομούμε (με κάποιο γνωστό αλγόριθμο ταξινόμησης) τα bins του ιστογράμματος και επιλέγουμε τις πρώτες  $N$  αποχρώσεις.

## Υφή



(Brodatz album, Vistex database)

## Περιγραφείς υφής

- Οι περιγραφείς χρώματος/έντασης αξιοποιούν πληροφορία απευθείας από τα εικονοστοιχεία.
  - Στατιστική κατανομή αποχρώσεων 1ης τάξης
- Οι περιγραφείς υφής αξιοποιούν πληροφορία που ενυπάρχει στις σχέσεις μεταξύ των αποχρώσεων των εικονοστοιχείων
  - Στατιστική κατανομή αποχρώσεων 2ης ή ανώτερης τάξης




(Tuceryan & Jain, 1998)

## ΑΥΤΟΣΥΣΧΕΤΙΣΗ




$$\rho(x, y) = \frac{\sum_{u=0}^{N-1} \sum_{v=0}^{N-1} I(u, v)I(u+x, v+y)}{\sum_{u=0}^{N-1} \sum_{v=0}^{N-1} I^2(u, v)}$$

- Υπολογίζεται ένα διάνυσμα που προκύπτει από τον υπολογισμό ανά εικονοστοιχείο της αυτοσυσχέτισης σε μια περιοχή NxN της εικόνας (μεγάλο).
- Περιοδική για περιοδικά πρότυπα υφής.
- Μειώνεται αργά για πρότυπα χονδροειδούς υφής.
- Μειώνεται γρήγορα για πρότυπα λεπτής υφής.
- Έχει κορυφή στο (0,0) και είναι σχεδόν επίπεδη για τυχαία υφή.
- Για τη μείωση της διάτασης του διανύσματος της αυτοσυσχέτισης μπορούν να υπολογιστούν κεντρικές στατιστικές ροπές.



## ΑΥΤΟΣΥΣΧΕΤΙΣΗ



## ΑΥΤΟΣΥΣΧΕΤΙΣΗ



## ΑΥΤΟΣΥΣΧΕΤΙΣΗ




## Πίνακες συνεμφάνισης

- Πίνακες συνεμφάνισης (co-occurrence matrices) για την περιγραφή της υφής των εικόνων.
- Περιγράφει τις σχέσεις ανάμεσα σε ζεύγη εικονοστοιχείων προς μια κατεύθυνση
  - Στατιστική 2ης τάξης
- Χρησιμοποιείται ευρέως για την περιγραφή της υφής από το 1973 έως σήμερα!
- Είναι απλά ένα διδιάστατο ιστόγραμμα μεταβάσεων από μια απόχρωση σε άλλη

(Haralick et al, 1973)

## Πίνακες συνεμφάνισης

$$C_{\Delta x, \Delta y}^m(i, j) = \sum_{p=1}^m \sum_{q=1}^m \begin{cases} 1, & \text{if } I(p, q) = i \text{ and } I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{otherwise} \end{cases}$$



## Πίνακες συνεμφάνισης

```
cooc[][] ← 0;  
for i = 2 to rows-1  
{  
  for j = 2 to columns-1  
  {  
    cooc[image[i][j]][image[i][j+1]] =  
    cooc[image[i][j]][image[i][j+1]] + 1  
  }  
}
```

## Πίνακες συνεμφάνισης

- Για την κωδικοποίηση μιας υφής χρειάζονται συνήθως περισσότεροι του ενός πίνακες συνεμφάνισης
- Αυτοί υπολογίζονται για Δx και Δy τέτοια ώστε να λαμβάνονται υπόψη πρώτα γειτονικά εικονοστοιχεία στις 0, 45, 90, 135 μοίρες
- Επομένως συνήθως χρειάζονται 4 πίνακες συνεμφάνισης, γεγονός που οδηγεί σε διανύσματα χαρακτηριστικών πολύ μεγάλης διάστασης
- Για τη μείωση της διάστασης:
  - Κβάντιση των αποχρώσεων της εικόνας
  - Από τους 4 πίνακες υπολογισμός ενός μέσου πίνακα συνεμφάνισης
  - Από κάθε πίνακα συνεμφάνισης υπολογισμός στατιστικών μέτρων όπως είναι η μέση τιμή και η διακύμανση των στοιχείων του (μέτρα Haralick)

## Μέτρα Haralick

Συνολικά πρότεινε 14 μέτρα, ενδεικτικά αναφέρονται

1) *Angular Second Moment*:

$$f_1 = \sum_i \sum_j \{p(i,j)\}^2.$$

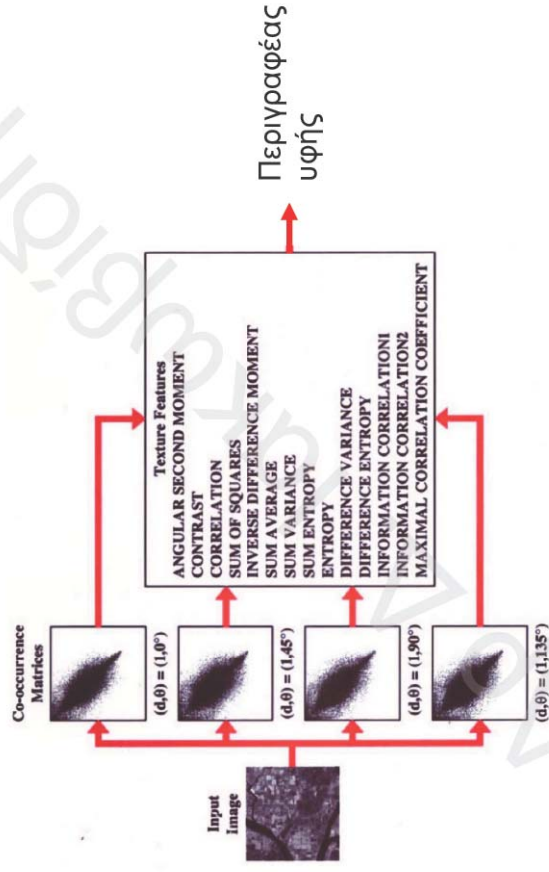
2) *Contrast*:

$$f_2 = \sum_{n=0}^{N_G-1} n^2 \left( \sum_{i=1}^{N_G} \sum_{j=1}^{N_G} p(i,j) \right) \cdot \left( |i-j| \right)$$

όπου  $N_G$  το πλήθος των αποχρώσεων του γκρι.

(Haralick et al, 1973)

## Μέτρα Haralick



## Τοπικά δυαδικά πρότυπα

- Ο αλγόριθμος των τοπικών δυαδικών προτύπων (Local Binary Patterns, LBP) έχει ως εξής:

- Για κάθε σημείο της εικόνας υπολογίζεται ένας αριθμός LBP, π.χ.

6	5	2
7	6	1
9	3	7

(a)

1	0	0
1	0	0
1	0	1

(b)

1	2	4
8	8	16
32	64	128

(c)

1	0	0
8	0	0
32	0	128

(d)

$$LBP = 1+8+32+128=169$$

- Κανόνας υπολογισμού: αν το περιφερειακό εικονοστοιχείο είναι μεγαλύτερο ή ίσο του κεντρικού τότε λαμβάνει τιμή 1 διαφορετικά 0.

(Maeraa & Pietikainen, 2004)

## Τοπικά δυαδικά πρότυπα

```


mask[3][3] = { {1, 2, 4},
               {8, 0, 16},
               {32, 64, 128} }

for i = 2 to rows-1
{
    for j = 2 to columns-1
    {
        lbp = 0;
        for k = 1 to 3
        {
            for l = 1 to 3
            {
                if (image[i][j] >= image[i+k-1][j+l-1])
                {
                    pattern[k][l] = 1 }
                else
                {
                    pattern[k][l] = 0 }
                pattern[k][l] = pattern[k][l] * mask[k][l]
                lbp = lbp + pattern[k][l]
            }
        }
        lbpImage[i][j] = lbp;
    }
}
    
```



## Τοπικά διαδικτικά πρότυπα

Υπολογίζεται το ιστόγραμμα των τιμών LBP από την περιοχή ενδιαφέροντος της εικόνας



Περιγραφέας:  
Ιστόγραμμα LBP τιμών

## Περιγραφείς υφής Gabor

- Η εικόνα συνελίσσεται με μάσκες Gabor που έχουν συντελεστές  $g$

$$r(x, y) = \iint_{\Omega} I(\xi, \eta)g(x - \xi, y - \eta) d\xi d\eta$$

- Οι συντελεστές των μάσκων υπολογίζονται ως:

$$g_{\lambda, \Theta, \varphi}(x, y) = e^{-((x'^2 + \gamma^2 y'^2)/2\sigma^2)} \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right)$$

$$x' = x \cos \Theta + y \sin \Theta, \quad y' = -x \sin \Theta + y \cos \Theta$$
$$\sigma = 0.56\lambda \quad \text{and} \quad \gamma = 0.5.$$



$$\text{ΕΝΔΕΙΚΤΙΚΑ } \Theta = k(\pi/8), \quad k = 0, 1, \dots, 7$$

$$\varphi = 0 \quad \varphi = -(1/2)\pi$$

(Grigorescu et al, 2002)

## Περιγραφείς υφής Gabor

Παράδειγμα συνάρτησης Gabor



(Grigorescu et al, 2002)

## Περιγραφείς υφής Gabor

- Τυπικοί περιγραφείς της υφής είναι οι ενέργειες Gabor που υπολογίζονται ως εξής:

$$e_{\lambda, \theta}(x, y) = \sqrt{r_{\lambda, \theta, 0}^2(x, y) + r_{\lambda, \theta, -(1/2)\pi}^2(x, y)}$$

$$p_{\lambda, \theta}(x, y) = e_{\lambda, \theta}^2(x, y)$$

(Grigorescu et al, 2002)

## Άσκηση

- Να προτείνετε τρόπους υπολογισμού των προηγούμενων χαρακτηριστικών υφής από έγχρωμες εικόνες

## Άσκηση

- Να προτείνετε τρόπους υπολογισμού των προηγούμενων χαρακτηριστικών υφής από έγχρωμες εικόνες
- Απάντηση
  - Εξαγωγή τους από κάθε χρωματικό κανάλι του RGB (οδηγεί σε πολύ μεγάλη διάσταση περιγραφέα)
  - Εξαγωγή τους μόνο από το κανάλι της έντασης, π.χ. I, Y, L,...

## Εφαρμογές

### Tumor Recognition in Endoscopic Video Images using Artificial Neural Network Architectures

- Είναι η πρώτη εργασία που αναφέρθηκε στον εντοπισμό πολυπόδων του παχέως εντέρου, το 2000.
- Χρήση πινάκων συσχετισμού και μέτρων Haralick.

## Εφαρμογές

- Πρόβλημα: Εντοπισμός όγκων (πολυπόδων) σε ενδοσκοπικές εικόνες αποχρώσεων του γκριζου.
- Προσέγγιση:
  - Εξαγωγή χαρακτηριστικών Haralick: angular second moment, correlation, inverse difference moment, entropy
  - Κβάντιση εικόνας σε 64 αποχρώσεις
  - Καθοδηγούμενη ταξινόμηση: Τεχνητό νευρωνικό δίκτυο πρόσθιας διάδοσης.



## Εφαρμογές


- Εντοπισμός πικνώσεων στον πνεύμονα
- Προβλήματα που αντιμετωπίζονται
  - Διαφορετικοί ασθενείς και διαφορετικές ρυθμίσεις της συσκευής, διαφορετικές εντάσεις στις ακτινογραφίες.
  - Εντοπισμός πικνώσεων με συνδυασμό χαρακτηριστικών έντασης και υφής.



(Tsevas & Iakovidis, 2011)

## Εφαρμογές


- Προτεινόμενη κανονικοποίηση
  - Ισοσταθμίζουμε το ιστόγραμμα (& διαιρούμε με 255  $\rightarrow$  [0, 1])
  - Εντοπίζουμε τη σπονδυλική στήλη από τα μέγιστα των προφίλ (μπλε).
  - Υπολογίζουμε τη μέση ένταση από τις περιοχές της σπονδυλικής στήλης.
  - Διαιρούμε την ένταση κάθε εικονοστοιχείου με τη μέση ένταση.
  - Λαμβάνουμε την κανονικοποιημένη εικόνα.



(Tsevas & Iakovidis, 2011)

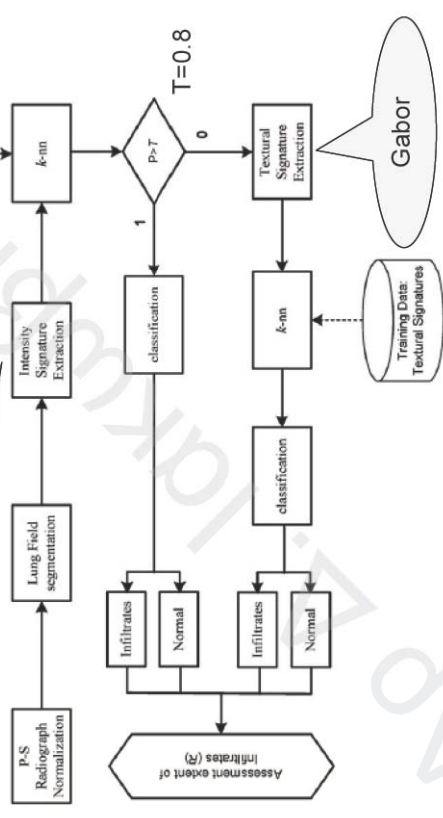
## Εφαρμογές

- Μετά την κανονικοποίηση οι εντάσεις διαφορετικών ακτινογραφιών γίνονται μεταξύ τους συγκρίσιμες.




## Εφαρμογές

Ιστογράμματα



(Tsevas & Iakovidis, 2011)


## Εφαρμογές























Επισημειωμένη ακτινογραφία



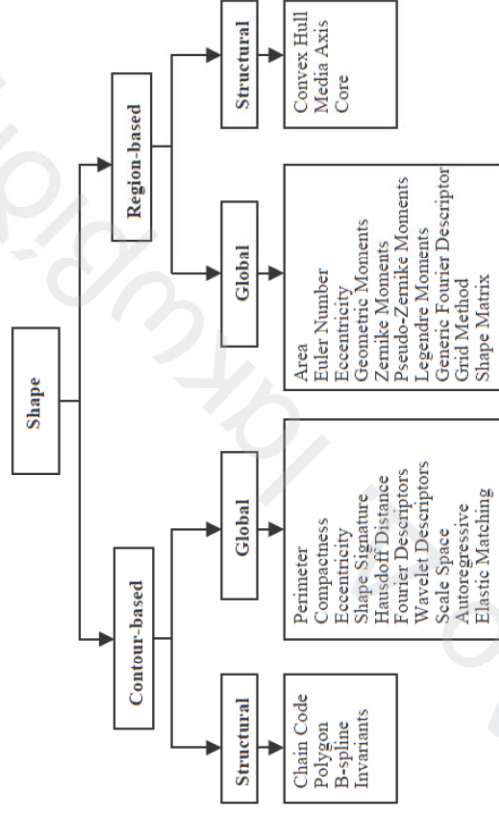
Αποτέλεσμα αλγορίθμου



## Σχήμα

Apple				
Bone				
Camel				
Device2				
Fly				


## Περιγραφείς σχήματος



(Zhang & Lu, 2004)

## Κωδικό αλυσίδα

- Δεδομένου ενός περιγράμματος το διατρέχουμε με τη φορά του ρολογιού ( $\beta$ ) και καταγράφουμε τον κωδικό κάθε κατεύθυνσης (c)
- Για κάθε κατεύθυνση υπάρχει κωδικός (a).
- Τελικά χρησιμοποιείται το ιστόγραμμα των κωδικών (d) ως περιγραφέας, ώστε να είναι ανεξάρτητος της αρχής.

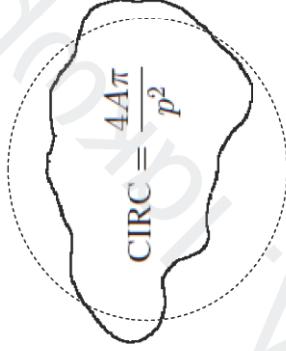


(Freeman & Saghri, 1978)



## Κυκλικότητα

- Η κυκλικότητα (circularity) είναι ένα απλό μέτρο που εκφράζει πόσο μοιάζει το σχήμα με κύκλο.


$$\text{CIRC} = \frac{4A\pi}{p^2}$$

- A είναι το εμβαδόν της περιοχής
- p είναι η περίμετρος της περιοχής

## Γεωμετρικές ροπές

$$M_{pq} = \sum_x \sum_y x^p y^q f(x, y)$$

Ροπή τάξης (p+q)

$$\bar{x} = \frac{M_{10}}{M_{00}} \quad \bar{y} = \frac{M_{01}}{M_{00}}$$

Κέντρο βάρους

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q$$

Κεντρικές ροπές  
(ανεξάρτητες μετατόπισης)

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^{\gamma}} \quad \gamma = (p + q / 2) + 1$$

Κεντρικές ροπές  
(ανεξάρτητες κλίμακας)

(Hu, 1968)

## Γεωμετρικές ροτές

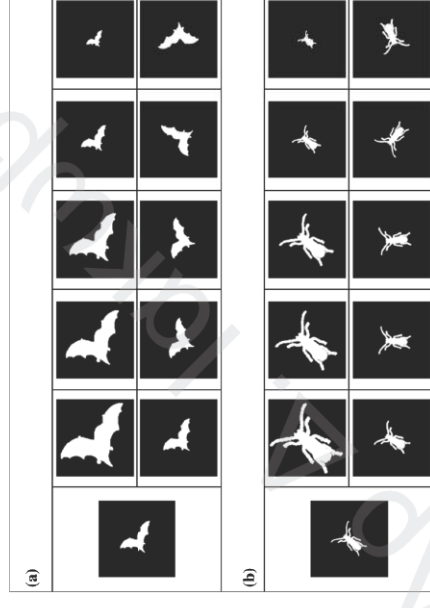
- Οι αμετάβλητοι περιγραφείς σχήματος του Hu

$$\begin{aligned}
 \phi_1 &= \eta_{20} + \eta_{02} \\
 \phi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\
 \phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (\eta_{03} - 3\eta_{21})^2 \\
 \phi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2 \\
 \phi_5 &= (3\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 \\
 &\quad - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \\
 &\quad \times [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
 \phi_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
 &\quad + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
 \phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 \\
 &\quad - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) \\
 &\quad \times [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
 \end{aligned}$$

(Hu, 1968)

## Εφαρμογές

Υπό μετατόπιση, στροφή και κλιμάκωση οι τιμές των ροτών διατηρούνται αμετάβλητες.



## Εφαρμογές

Ακόμα και σε εικόνες αποχρώσεων του γκριζου.




Original image	0.c01316 14f93f92 4657	4.02737 264e48 433e-07	4.919074 3688c4 43e-11	1.7485 068369 965e-11	4.33688 454504 509e-22	6.39867 4764168 45e-15	2.714314 2645091 6e-22
Half Sized	0.c0131 602779 328601	4.02637 3735950 75e-07	4.91559 724698 639e-11	1.74506 0495941 10e-11	4.33304 5126686 17e-22	6.39214 3192477 97e-15	2.71049 808296 574e-22
Rotated (45°)	0.c0181 6971821 45c80	4.02823 4687051 56e-07	4.94096 39300 748e-11	1.73701 3658192 9e-11	4.89957 2131187 58e-22	6.41169 4423271 09e-15	2.74333 842758 657e-22

Οι τιμές των 7 γεωμετρικών ροπών

## Εφαρμογές

Αναγνώριση μελανώματος




(Maglogiannis & Doukas, 2009)

## Εφαρμογές

Αξιολόγηση ανώμαλων ορίων

- Η ομαλότητα των ορίων μπορεί να αξιολογηθεί αξιοποιώντας την έννοια της κυκλικότητας (circularity)



(Maglogiannis & Doukas, 2009)

## Επιλογή χαρακτηριστικών

- Αποσκοπεί στην επιλογή των καταλληλότερων χαρακτηριστικών.
- Δηλαδή στην επιλογή των χαρακτηριστικών εκείνων που δημιουργούν περισσότερο διαχωρίσιμες κλάσεις.
- Τρεις βασικές κατηγορίες μεθόδων
  - Φίλτρου (filter) } Συνήθως βασίζονται σε στατιστικό κριτήριο
  - Περιβάλλουσες (wrapper) } Βασίζονται στον ταξινομητή
  - Ενσωματωμένες (embedded)

## Μέθοδοι φίλτρου

- Ενδεικτικό παράδειγμα μεθόδου φίλτρου αποτελεί η μέθοδος της βαθμονόμησης χαρακτηριστικών βάσει του στατιστικού κριτηρίου  $t$ -test
- Σύμφωνα με το Welch's  $t$ -test
  - Για κάθε χαρακτηριστικό  $f$  στον πίνακα των δεδομένων μας υπολογίζεται η μέση τιμή  $m$  και η τυπική αποκλιση  $\sigma$  των τιμών του για κάθε κλάση  $\omega_j$  και  $\omega_h$ , θεωρώντας ότι κάθε κλάση έχει  $n_j$  και  $n_h$  πλήθος στοιχείων.
  - Κάθε χαρακτηριστικό λαμβάνει ένα βαθμό  $Z(f)$

$$Z(f) = \frac{|m_f^j - m_f^h|}{\sqrt{\frac{(\sigma_f^j)^2}{n_j} + \frac{(\sigma_f^h)^2}{n_h}}}$$

## Μέθοδοι φίλτρου

- Τα χαρακτηριστικά που επιλέγονται πρέπει να είναι επίσης όσο το δυνατόν ασυσχέιστα μεταξύ τους
- Αλλά και να υπάρχει όσο το δυνατόν μεγαλύτερη συσχέτιση με την κλάση.
- Η συσχέτιση ανάμεσα σε δύο ποσότητες  $x$  και  $y$  υπολογίζεται από τη σχέση (Pearson's correlation coefficient):

$$d(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

## Περιβάλλουσες μέθοδοι

- Οι περιβάλλουσες μέθοδοι δοκιμάζουν υποσύνολα των διαθέσιμων χαρακτηριστικών προκειμένου να εντοπίσουν το βέλτιστο βάσει της απόδοσης ενός ταξινόμητή.
- Εξαντλητική αναζήτηση
  - Δοκιμάζονται όλοι οι δυνατοί συνδυασμοί υποσυνόλων του συνόλου των διαθέσιμων χαρακτηριστικών.
  - Υπολογιστικά πολύπλοκο ειδικά για πολλά χαρακτηριστικά.
  - Στις περιβάλλουσες μεθόδους περιλαμβάνονται αλγόριθμοι που αναζητούν πιο έξυπνα το βέλτιστο υποσύνολο.

## Περιβάλλουσες μέθοδοι

- Σειριακή εμπρόσθια επιλογή χαρακτηριστικών
  - Sequential Forward Selection (SFS)
- Βήματα
  - Ως κριτήριο για την επιλογή των χαρακτηριστικών χρησιμοποιείται η απόδοση του ταξινόμητή, π.χ. η ακρίβεια.
  - Επιλέγεται το καλύτερο χαρακτηριστικό βάσει του κριτηρίου.
  - Δοκιμάζονται ζεύγη του καλύτερου χαρακτηριστικού με τα υπόλοιπα
  - Επιλέγεται το καλύτερο ζεύγος.
  - Η διαδικασία επαναλαμβάνεται είτε έως ότου επιλεγθούν Κ χαρακτηριστικά.
- Σειριακή οπισθοδρομική επιλογή χαρακτηριστικών
  - Sequential Backward Selection (SBS)
  - Λειτουργεί όπως και η SFS με τη διαφορά ότι ξεκινά επιλέγοντας όλα τα χαρακτηριστικά και αφαιρώντας ένα κάθε φορά.

## Εφαρμογές

- Εξαγωγή χαρακτηριστικών από superpixels.
- Οι μέθοδοι επιλογής χαρακτηριστικών διαθέσιμες στη Weka.
- Χαρακτηριστικά
  - Ροπές έως και 3ης τάξης
  - Από χρωματικά κανάλια  $X=\{R, G, B, L, a, b, H, S, V, F1, F2, F3\}$

Method (feature subset)	Sens.	Spec.	AUC
CFS ( $\mu_a, \sigma_a, \mu_s$ )	0.96±0.00	0.91±0.03	0.94±0.01
IG, $\chi^2$ ( $\mu_a, \mu_{FI}, \mu_{F3}$ )	0.95±0.00	0.85±0.03	0.90±0.02
GR ( $\mu_a, \mu_s, \mu_{F1}$ )	0.95±0.01	0.86±0.05	0.90±0.03
RFE ( $\sigma_a, \mu_H, \sigma_s$ )	0.93±0.00	0.77±0.11	0.85±0.05

CFS = Correlation-based feature selection

(Iakovidis et al, 2015)

## Από τη θεωρία στην πράξη

- Επεξεργασία εικόνας
  - ImageJ
  - Matlab
- Εξαγωγή χαρακτηριστικών
  - Matlab
- Επιλογή χαρακτηριστικών
  - Weka
- Ταξινόμηση / συσταδοποίηση χαρακτηριστικών
  - Weka

## Από τη θεωρία στην πράξη

- Εναλλακτικά μπορεί να χρησιμοποιηθεί αποκλειστικά:
  - Matlab ή
  - C/C++ (υπάρχουν βιβλιοθήκες όπως η OpenCV)
  - Java (υπάρχουν βιβλιοθήκες όπως η BoofCV, JavaCV, ImageJ, JAI...)