

# Projecte final de carrera

Enginyeria en informàtica

Àrea de Visió per computador

## Anàlisi de la viabilitat de la utilització d'histogrames de color per a la classificació d'obres d'art

Memòria presentada per

Luis Pumares Carceller

gener-11

## Índex

Il·lustracions.....	4
Taules.....	6
1. Introducció.....	8
1.1. Àmbit del projecte.....	8
1.2. Estat de l'art actual.....	16
1.3. Objectius.....	18
2. Planificació del projecte.....	19
2.1. Identificació de les tasques.....	19
2.2. Planificació temporal.....	20
2.3. Descripció dels capítols seguits.....	20
3. Especificació dels casos d'ús.....	21
3.1. Condicions prèvies.....	21
3.2. Procediment pas a pas.....	23
3.3. Resultat esperat.....	23
4. Disseny tècnic.....	24
4.1. Primer nivell d'anàlisi descendent.....	24
4.2. Segon nivell d'anàlisi descendent.....	26
4.3. Algorisme de validació de la classificació del conjunt d'aprenentatge.....	27
4.4. Algorisme de classificació.....	28
4.5. Funcions utilitzades d'OpenCV.....	30
5. Documentació tècnica.....	32
5.1. Estructura de carpetes.....	32
5.2. Diagrama de classes.....	33
5.3. Execució.....	35

6.	Proves i resultats .....	37
6.1.	Proves realitzades .....	37
	Cas 1: Dupliquem les imatges – 100% encert esperat.....	37
	Cas 2: Dupliquem les imatges però en les còpies canviem l'autor (esperem un 0% d'encert).....	41
6.2.	Aplicació: Classificació per l'atribut "format" .....	44
6.3.	Aplicació: Classificació per l'atribut "tipus" .....	53
6.4.	Aplicació: Classificació per l'atribut "autor" .....	57
6.5.	Aplicació: Classificació per l'atribut "escola" .....	72
6.6.	Aplicació: Classificació per l'atribut "període" .....	76
7.	Conclusions y treballs futurs .....	81
7.1.	Conclusions.....	81
7.2.	Propostes per continuar.....	82
8.	Bibliografia .....	83
9.	Apèndix .....	84
9.1.	Origen de les imatges de les obres d'art.....	84

## II·lustracions

II·lustració 1 Cerca d'una imatge orientada horitzontalment.....	9
II·lustració 2 Cerca d'una imatge orientada verticalment .....	9
II·lustració 3 Esquema de relacions entre visió per ordinador i altres àrees afins.....	10
II·lustració 4 Imatge original en color .....	12
II·lustració 5 Descomposició en canals .....	13
II·lustració 6 Histogrames de color RGB .....	13
II·lustració 7 Anàlisi d'un píxel als histogrames de color.....	14
II·lustració 8 procés aplicat en el procés de reconeixement facial .....	16
II·lustració 9 Exemple d'imatges semblants i diferents .....	17
II·lustració 10 Exemple fitxer url.txt .....	22
II·lustració 11 Exemple fitxer labels.txt.....	22
II·lustració 12 Anàlisi descendent: primer nivell .....	25
II·lustració 13 Procediment 3-fold cross validation .....	27
II·lustració 14 Estructura projecte ProjecteMuseus .....	32
II·lustració 15 Diagrama de classes del projecte .....	33
II·lustració 16 Cas1: fitxer url.txt .....	38
II·lustració 17 Cas1: fitxer labels.txt.....	38
II·lustració 18 Descàrrega de les imatges a la carpeta local. ....	40
II·lustració 19 Contingut carpeta local un cop descarregades les imatges.....	40
II·lustració 20 Resultat de la classificació.....	41
II·lustració 21 Cas2: fitxer labels.txt.....	41
II·lustració 22 Resultat de la classificació – mode debug activat .....	43
II·lustració 23 Execució #1: fitxer url.txt .....	44
II·lustració 24 Execució #1: fitxer labels.txt.....	45

Il·lustració 25 Resultat execució #1 amb K=1.....	46
Il·lustració 26 Resultat run1 amb K=1 en mode debug (classificació fold1).....	46
Il·lustració 27 Comparació dels histogrames de les imatges #3 i #4.....	47
Il·lustració 28 Comparació dels histogrames de les imatges #6 i #13.....	48
Il·lustració 29 Execució #1: fitxer url.txt.....	48
Il·lustració 30 Execució #2: fitxer labels.txt.....	49
Il·lustració 31 Imatges execució #2.....	49
Il·lustració 32 Log execució #2 amb K=1.....	50
Il·lustració 33 Log execució #2 amb K=3.....	51
Il·lustració 34 Obres d'art de la execució 35.....	70
Il·lustració 35 Comparació Histogrames de les imatges #38 i #11.....	71
Il·lustració 36 Cercador de la web.....	84
Il·lustració 37 Opció de descàrrega d'imatges.....	84

## Taules

Taula 1 Tasques de la fase d'anàlisi.....	19
Taula 2 Diagrama de gant de les fases del projecte.....	20
Taula 3 Paràmetres del constructor classe Classificador.....	24
Taula 4 Paràmetres de la crida al programa ProjecteMuseus.exe.....	35
Taula 5 Sortida del programa quan el nombre d'argument és incorrecte.....	36
Taula 6 Llista d'autors del Cas 1.....	37
Taula 7 Llista d'obres del Cas 1.....	37
Taula 8 Resultats test 1.....	39
Taula 9 Resultats test 2.....	42
Taula 10 Llista de forms.....	44
Taula 11 Llista d'obres de la execució #1.....	44
Taula 12 Llista de forms.....	47
Taula 13 Llista d'obres execució #2.....	48
Taula 14 Llista de classes de la execució #3.....	53
Taula 15 Llista d'imatges de la execució #3.....	53
Taula 16 Llista de classes de la execució #4.....	57
Taula 17 Llista d'imatges de la execució #4.....	58
Taula 18 Llista de classes de la execució #5.....	62
Taula 19 Llista d'imatges de la execució #5.....	62
Taula 20 Llista de classes de la execució #6.....	66
Taula 21 Llista d'imatges de la execució #6.....	66
Taula 22 Llista de classes de la execució #7.....	72
Taula 23 Llista d'imatges de la execució #7.....	72
Taula 24 Llista de classes de la execució #8.....	76

Taula 25 Llista d'imatges de la execució #8 .....76

# 1. Introducció

## 1.1. Àmbit del projecte

La visió per computador és una branca de la intel·ligència artificial que desenvolupa sistemes en temps real de visió per computadora i processament d'imatges amb aplicacions de reconeixement d'objectes, patrons, colors i formes. Una de les principals àrees d'aplicació és el control de qualitat de productes industrials. Altres camps d'aplicació són la biomedicina i els sistemes relacionats amb la seguretat.

L'objectiu de la visió artificial és desenvolupar un programari que pugui analitzar i reconèixer les característiques d'una imatge. Els objectius típics de la visió artificial inclouen:

- ❑ El reconeixement de certs objectes en imatges (per exemple, cares humanes).

Actualment hi ha aplicacions per emmagatzemar imatges, com *Picassa* de *Google*, que són capaces d'extreure imatges de les cares humanes de les fotografies desades i reconèixer les semblances entre elles.

- ❑ Seguiment d'un objecte en una seqüència d'imatges.

Al món de l'esport, com ara el tennis, s'han desenvolupat sistemes que permeten analitzar el vídeo enregistrat per les càmeres i fer un seguiment de la trajectòria de la pilota per determinar si la pilota ha anat fora del terreny de joc o no. També, permet fer el seguiment dels jugadors d'un equip de futbol i obtenir dades com ara la distància recorreguda en un partit, o la possessió i la localització de la pilota.

- ❑ Mapeig d'una escena per generar un model tridimensional de l'escena; aquest model podria ser usat per un robot per navegar per l'escena.
- ❑ Estimació de les postures tridimensionals d'humans.
- ❑ Cerca i classificació d'imatges digitals pel seu contingut.

Google fa temps que té la idea de fer un cercador d'imatges igual com existeix un cercador de paraules. (<http://images.google.es/>). Permet cercar imatges semblants a una determinada. No obstant això, els algorismes tenen certes limitacions: l'orientació del objecte determina el conjunt d'imatges semblants.

Per exemple, si cerquem una fotografia d'una cara horitzontal el resultat és:





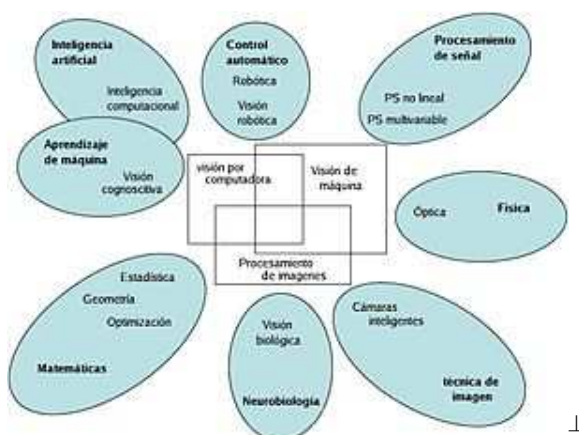
**Il·lustració 1 Cerca d'una imatge orientada horitzontalment**

Mentre que si la orientem correctament (verticalment) el resultat de la cerca és millor:



**Il·lustració 2 Cerca d'una imatge orientada verticalment**

En general, aquests objectius s'aconsegueixen mitjançant el reconeixement de patrons, l'aprenentatge estadístic, la geometria de projecció, el processament d'imatges, la teoria de gràfics, etc. La visió artificial cognitiva està relacionada amb altres disciplines com ara la computació biològica, la psicologia, la robòtica, etc.



Il·lustració 3 Esquema de relacions entre visió per ordinador i altres àrees afins.

Notem que la visió artificial cognitiva està molt lligada a la robòtica, ja que els sistemes de visió per computador són la principal font d'informació dels robots.

### Visió per Computador als museus

Tal com s'explica a la web de l'institut de recerca de la UOC (IN3)

([http://in3.uoc.edu/opencms\\_portalin3/opencms/ca/recerca/list/sunai\\_scene\\_understanding\\_and\\_artificial\\_intelligence\\_lab](http://in3.uoc.edu/opencms_portalin3/opencms/ca/recerca/list/sunai_scene_understanding_and_artificial_intelligence_lab)), un camp d'aplicació de la intel·ligència artificial és el reconeixement d'imatges dels museus.

*Els museus actuals ofereixen als seus visitants un gran ventall d'obres d'art, des de les clàssiques pintures i escultures, a l'art contemporani que pot combinar objectes en moviment, produccions audiovisuals o inclús persones. Algunes d'aquestes obres són difícils d'apreciar sense una correcta informació del seu context artístic i temporal, i aquesta necessitat d'informació sovint no és coberta per les audio-guides actuals. Els avenços tecnològics en dispositius mòbils fan pensar en la possibilitat d'utilitzar aplicacions de realitat augmentada que aportin aquesta informació, i facilitin l'acostament del públic no expert als museus.*

*Aquesta línia vol avançar en l'anàlisi i implementació dels mètodes de Visió per Computador necessaris per a fer viable l'introducció de la realitat augmentada als museus. Entre els temes*

*d'interès hi ha: El reconeixement automàtic obres d'art des de qualsevol punt de vista, l'assistència en el manteniment dels catàlegs artístics (anàlisi automàtic de les obres per determinar època, autor, tipus, materials, ...), detecció de parts o estructures comunes entre obres (trobar influències entre autors o trets característics d'un autor), anàlisi del contingut de les obres (cerca de persones i anàlisi de les seves expressions facials, interacció entre les persones de les obres), ...*

Entenem per reconeixement d'imatges (en aquest cas d'obres d'art) el fet de predir-ne els atributs (autor, tècnica, etc) mitjançant un conjunt d'entrenament donat. El reconeixement d'imatges es basa en l'extracció de característiques de les mateixes, i comparar-les amb les dades que es tenen del conjunt d'entrenament. Aquesta comparació permet triar les imatges més semblants del nostre conjunt d'entrenament, de les quals coneixem a priori els valors dels atributs que volem classificar (autor, tècnica, etc). Notem que qualsevol comparació entre característiques va lligada una noció de distància.

En aquest treball distingim entre

❑ **Atributs** d'una obra d'art

Són les dades que permeten catalogar una obra d'art:

- Autor
- Tècnica
- Classe d'obra d'art (pintura, escultura, etc)
- Tipus d'obra d'art (paisatge, etc)
- Escola de l'artista
- Període

❑ **Característiques** d'una obra d'art

És la informació intrínseca a les obres d'art i que permet fer comparacions entre elles. Cal un procediment per extreure aquesta informació de l'obra d'art. Tenim per exemple, els histogrames o les característiques geomètriques.

En aquest treball ens centrarem en la problemàtica d'identificar si l'anàlisi dels histogrames de les imatges és rellevant per a la classificació d'obres d'art.

## Histogrames d'imatges

A partir d'una imatge es pot obtenir el seu histograma de color. Un histograma de color representa el nombre de píxels que té un color determinat d'una gamma predeterminada de colors. Per definir aquest rang de colors cal discretitzar el conjunt de colors de la imatge. Per aconseguir això es fa servir el model RGB on cada color es pot interpretar com un conjunt de 3 intensitats corresponents als valors dels color primaris: vermell (R), blau (B) i verd (G). En altres paraules, cada píxel té un valor numèric assignat tonal per a cada un dels tres canals de color R, G i B. Per exemple, les coordenades d'un píxel de color poden ser  $255R+255G+0B$ . Recordem que el blau més verd fa CIAN, blau més vermell fa MAGENTA i vermell més verd fa groc. Per tant el color del píxel que s'ha descrit anteriorment,  $255R+255G+0B$ , seria groc pur. Quan les coordenades de color d'un píxel són iguals, es té una escala de grisos que va des del negre pur ( $0R+0G+0B$ ), passant pel gris ( $127R+127G+127B$ ) i finalitzant amb el blanc pur ( $255R+255G+255B$ ).

L'histograma de color és doncs un histograma 3D en què cada color ve determinat pels valors de les 3 intensitats de cada color primari RGB que el defineixen. A l'histograma a cada vector 3D li correspon el nombre de píxels que tenen aquest color. Aquest histograma 3D és equivalent a 3 histogrames 1D, un per cada color del model RGB.

Per exemple, la imatge següent



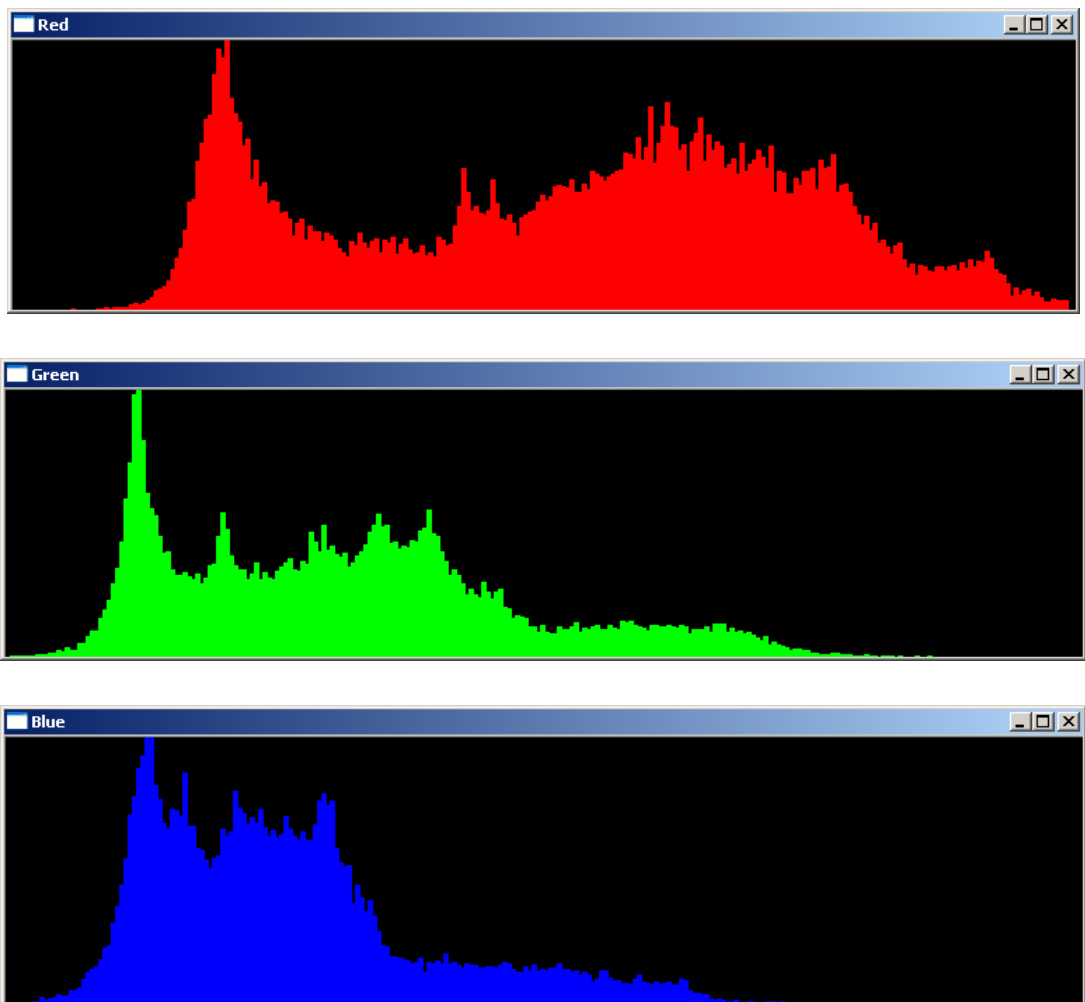
Il·lustració 4 Imatge original en color

Podem obtenir la descomposició de la imatge en els 3 canals RGB



Il·lustració 5 Descomposició en canals

Podem calcular l'histograma per cadascun d'aquests canals. En aquest cas tenim:

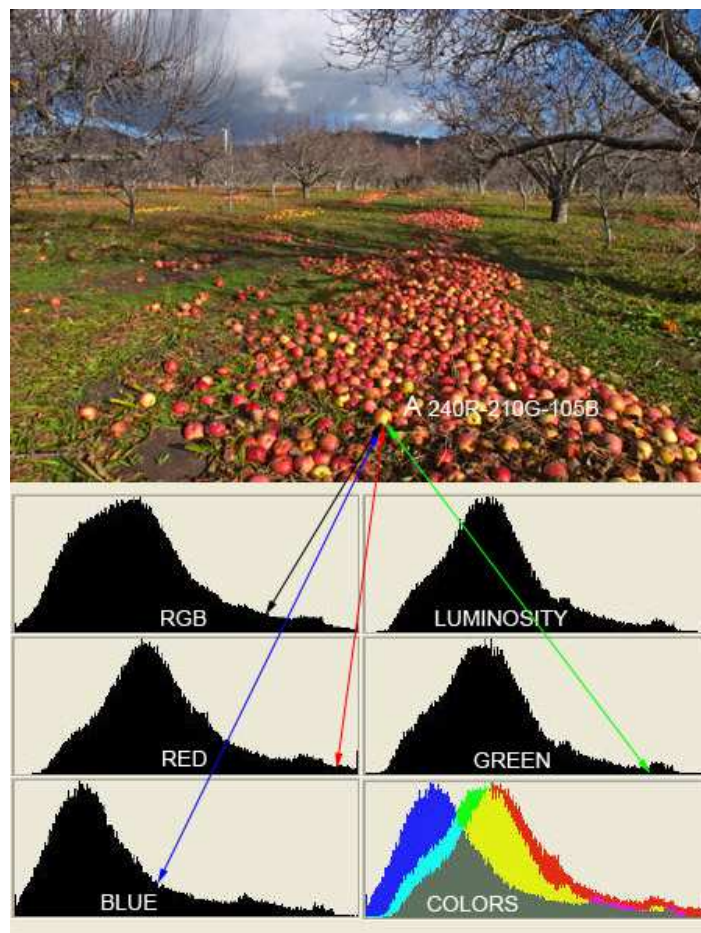


Il·lustració 6 Histogrames de color RGB

Aquests histogrames defineixen la distribució de color a la imatge. En l'eix horitzontal tenim les distintes intensitats i en l'eix vertical tenim el nombre de píxels amb aquesta intensitat.

Notem que el color vermell és el predominant, perquè té més presència a la dreta de l'eix horitzontal (zona d'intensitats majors).

Un altre exemple extret de l'article *A PRACTICAL GUIDE TO INTERPRETING RGB HISTOGRAMS* (<http://www.sphoto.com/techinfo/histograms/histograms2.htm>), mostra una imatge d'un paisatge de tardor a Califòrnia



Il·lustració 7 Anàlisi d'un píxel als histogrames de color

L'autor es fixa en una poma del dibuix corresponent a un píxel de coordenades **240R+210G+105B** a l'espai RGB. Les fletxes mostren la posició del píxel als histogrames. Notem que el vermell és el color predominant (240R) amb el verd no gaire lluny (210G). En el model RGB vermell més verd fan groc. La

contribució del blau (que és el complementari del groc) fa disminuir la contribució del groc al color final. Per això la poma té un color groc vermellós.

Notem també que l'histograma blau està desplaçat a l'esquerra (zona d'intensitats baixes), a causa del predomini dels colors càlids a la imatge.

### **Algorisme de classificació**

Queda clar, doncs, que l'histograma de color ens dóna informació rellevant sobre les obres d'art. No obstant això, la pregunta que volem respondre en aquest treball és: Es poden fer servir els histogrames de color per classificar obres d'art?

Quan diem classificar obres d'art ens referim a predir correctament el valor d'un atribut determinat: tècnica, autor, període, tipus d'obra d'art, etc.

Per fer aquestes classificacions ens caldrà tenir un conjunt d'obres d'art de referència, el conjunt d'entrenament, del qual coneixem a priori els valors de l'atribut que volem analitzar.

Per realitzar la classificació sovint s'utilitza l'algorisme consistent en la cerca dels "k" dels veïns més propers a l'element que volem classificar (algorismes KNN). Per cercar els veïns més propers ens caldrà tenir definida una noció de distància entre histogrames. Per fer això farem servir les eines de l'**OpenCV** que permeten comparar histogrames.

Finalment, farem servir la tècnica de *K-fold cross validation* per validar la bondat d'aquest algorisme de classificació aplicat a l'ús d'histogrames de color.

Més endavant, en l'apartat de disseny tècnic, detallarem aquests algorismes.

### **Tecnologia pel desenvolupament del programari**

El programari que ens permetrà analitzar els conjunt d'entrenament serà desenvolupat en C++ fent servir l'IDE **Microsoft Visual Studio 2010** i es farà ús de les llibreries **OpenCV** (<http://opencv.willowgarage.com>) de tractament d'imatges.

## 1.2. Estat de l'art actual


### Reconeixement d'imatges

El reconeixement d'imatges s'aplica a diverses àrees amb diferents especificitats. Per exemple, al món de la indústria es fa servir per reconèixer automàticament defectes dels productes acabats, en la medicina poden servir d'ajut per prediagnosticar malalties com ara el càncer de mama femení, o al món de la seguretat per reconèixer cares humanes dins d'una base d'imatges determinada. En cadascun d'aquests casos cal trobar quins atributs i quins mecanismes són els més adients per fer les classificacions.

En general, el reconeixement visual d'objectes és una tasca difícil. La tecnologia actual de la visió per ordinador ofereix un bon reconeixement quan es tracta d'un petit nombre d'objectes, però no si s'ha de diferenciar entre un gran nombre d'objectes i entre les diferents classes d'objectes (veure <http://robotzeitgeist.com/tag/object-recognition>).

En el cas del reconeixement facial i d'altres característiques biomètriques, en els darrers anys hi ha hagut un gran creixement de solucions comercials en solucions de vídeo vigilància desenvolupats per empreses com *Cognitec*, *Eyematic*, *Viisaje* i *Identix*.

El següent diagrama de bloc, extret d'un estudi d'en *Roger Gimeno Hernández* de la UPC, ([http://upcommons.upc.edu/pfc/bitstream/2099.1/9782/1/PFC\\_RogerGimeno.pdf](http://upcommons.upc.edu/pfc/bitstream/2099.1/9782/1/PFC_RogerGimeno.pdf)), ens mostra el procés aplicat en el procés de reconeixement facial



**Il·lustració 8** procés aplicat en el procés de reconeixement facial

Notem que ens cal tenir un procediment per a extreure característiques (el patró de la imatge) que després es procedirà a classificar contra una base d'imatges de referència.


En general, el problema consisteix en trobar un conjunt de característiques que es puguin fer servir en el procés de classificació. Si cal analitzar moltes característiques de manera simultània, s'incrementa molt la complexitat del problema i cal trobar mètodes per a reduir-la, i passar a treballar amb un grup reduït de característiques no correlacionades (anomenades característiques principals). Els mètodes més utilitzats són el PCA (Principal Component Analysis), el LPP (Locality Preserving Projections) i el DCT (Discrete Cosine Transform).



Un cop tenim un conjunt reduït de característiques, cal aplicar un algorisme de classificació. Els més comuns són els dels veïns més propers, *support Vector Machines*, Hidden Markov Models, xarxes bayesianes, etc.

En general el problema central del reconeixement d'imatges és el càlcul de la distància entre imatges. Per a imatges amb pocs píxels i monocromàtiques, una bona opció és la generalització de la distància euclidiana: IMED (Image Euclidean Distance). Aquesta es defineix com la diferència, per a cada píxel, de les intensitats de gris de les dues imatges comparades (font:

<http://www.cis.pku.edu.cn/faculty/vision/wangliwei/pdf/IMED.pdf>)



Il·lustració 9 Exemple d'imatges semblants i diferents

L'ús d'aquesta distància, es pot fer servir tant d'una manera més immediata en els algorismes de cerca directa com el de veïns més propers, o en els algorismes de PCA per reduir la complexitat del problema.

### L'ús dels histogrames al reconeixement d'imatges.

S'ha avançat molt en l'estudi de la relació entre els histogrames dels colors i les propietats físiques dels objectes. S'ha demostrat que els histogrames donen informació no solament sobre el color de l'objecte, sinó sobre les propietats físiques de les superfícies. Llavors, assumint que els quadres d'una determinada època i autor estan pintats sobre la mateixa mena de superfícies –o molt similars-, sembla que aquesta anàlisi ens pot anar bé per classificar-les.

En general, la classificació d'objectes mitjançant histogrames de color pot fallar en el reconeixement d'objectes similars que tenen colors diferents. En aquests casos, s'hauria de completar l'anàlisi amb la inclusió d'altres característiques. No obstant això, s'ha demostrat que en algunes condicions l'anàlisi del color pot ser eficient. En aquest treball intentarem veure si funciona bé per a classificar les obres d'art.

S'han realitzat estudis d'anàlisi de quines característiques són rellevants per classificar obres d'art. Per exemple, a l'article **Print ISBN: 978- Image Feature Extraction and Recognition of Abstractionism and Realism Style of Indonesian Paintings 1-4244-8746-2**, es fa referència a l'ús de les següents característiques: Gabor wavelet, anàlisi d'histogrames i anàlisi de línies, pel reconeixement d'un tipus concret de pintures. L'article conclou que l'anàlisi de línies va donar la millor precisió amb un 66,23% d'encert.

### 1.3. **Objectius**

L'objectiu principal d'aquest treball és establir si l'anàlisi dels histogrames de color és eficient per classificar obres d'art. Llavors,

- ❑ A partir d'un conjunt d'imatges d'obres d'art els atributs de les quals coneixem, generarem un programari que ens permeti establir la precisió de la classificació en cas que es fes servir com a conjunt d'entrenament per a reconèixer altres imatges.
- ❑ Com a característica de classificació farem servir els histogrames de color i la noció de distància disponible per a les llibreries openCV.
- ❑ Com a algorisme de classificació farem servir l'algorisme KNN dels K veïns propers.
- ❑ Farem servir la tècnica de *K-fold cross validation* per validar la bondat d'aquesta classificació.
- ❑ Aplicarem el programari a diferents conjunts d'imatges i per a diferents atributs.
- ❑ Finalment presentarem les nostres conclusions.

## 2. Planificació del projecte

### 2.1. Identificació de les tasques

Les tasques identificades s'agrupen en les diferents fases del projecte:

#### 1. Anàlisi

Tasca
1.1 Anàlisi de l'estat de l'art
1.2 Anàlisi de funcionalitats de l'Open CV
1.3 Especificació de casos d'ús
1.4 Disseny tècnic
1.5 Especificació de les proves

Taula 1 Tasques de la fase d'anàlisi

#### 2. Desenvolupament

Desenvolupament en **Visual Studio 2010 + OpenCV**

Aquesta fase ha de començar amb l'acabament de la fase 1.4 i es pot desenvolupar en paral·lel amb la tasca 1.5.

#### 3. Fase de proves

En aquesta fase s'han d'executar les proves definides a la fase 1.5 amb el codi de la fase 2. Llavors, aquesta fase ha de començar amb l'acabament de la fase 1.5 i la fase 2. També inclou la resolució d'errors.

#### 4. Tancament

Aquesta fase ha de començar amb l'acabament de la fase 3.

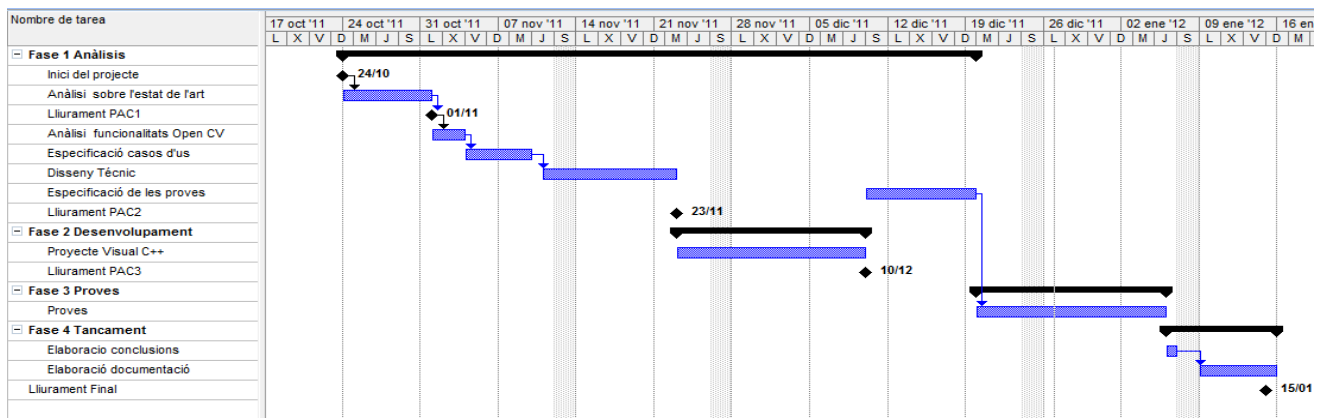
Inclou:

- Elaborar una memòria del projecte que inclogui les conclusions
- Elaborar una presentació en format powerpoint amb àudio
- Elaborar un petit manual d'usuari

La data de lliurament del projecte és el 15 gener 2011.

## 2.2. Planificació temporal

A continuació presentem el diagrama de Gantt amb la planificació de les tasques identificades anteriorment; s'hi inclouen les fites corresponents a les dates de lliurament final i parcial (PACs)



Taula 2 Diagrama de gant de les fases del projecte

## 2.3. Descripció dels capítols següents

Els següents capítols s'organitzen segons les fases del projecte. Al capítol 3 especificarem l'únic cas d'ús que s'ha d'implementar. Al capítol 4 es detalla la anàlisi tècnica del projecte, incloent l'especificació dels algorismes utilitzats. Al capítol 5 tenim la informació tècnica del projecte, incloent el diagrama de classes del programari generat. Al capítol 6 mostrem els resultats de l'aplicació del programari per respondre a la pregunta que ens fem sobre la rellevància dels histogrames de color per la classificació d'imatges. Les primeres execucions corresponen a casos de test que ens permeten avaluar el correcte funcionament del programa. La resta de casos són aplicacions a diversos conjunts d'imatges. En aquests casos apliquem el programari, interpretem els resultats i establim conclusions. Les conclusions i les propostes de millora es presenten formalment al capítol 7.

## 3. Especificació dels casos d'ús

A continuació especificuem l'únic cas d'ús que tenim. Consisteix en calcular la bondat de la classificació d'un conjunt de d'imatges d'obres d'art mitjançant la comparació dels seus histogrames de color.

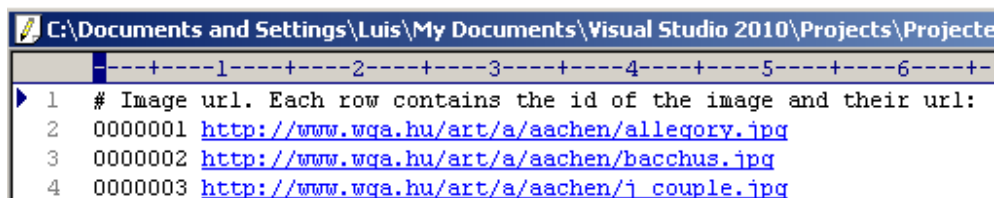
### 3.1. Condicions prèvies

Tenim un conjunt d'imatges d'obres d'art que volem classificar comparant els seus histogrames de color. Per especificar aquest conjunt, cal crear un directori amb una sèrie de fitxers de text amb la següent informació:

<code>\images</code>	→	carpeta arrel
<code>+++ \local</code>	→	en aquesta carpeta es farà una copia local de les imatges
<code>+++ authorsData.txt</code>	→	info: detalls dels autors
<code>+++ imagesData.txt</code>	→	info: detalls de les imatges
<code>+++ labels.txt</code>	→	valors dels atributs de cada imatge
<code>+++ url.txt</code>	→	URL de les imatges a baixar
<code>+++ authors.dict</code>	→	info: detalls dels autors
<code>+++ forms.dict</code>	→	info: detalls dels formats
<code>+++ schools.dict</code>	→	info: detalls de les escoles
<code>+++ techniques.dict</code>	→	info: detalls de les tècniques
<code>+++ timeFrames.dict</code>	→	info: detalls dels períodes
<code>+++ types.dict</code>	→	info: detalls dels tipus d'obres

Distingim entre els fitxers amb informació addicional, que no tenen més rellevància, i els fitxers importants que defineixen el conjunt d'obres d'art a analitzar. Aquests últims són:

- el fitxer `url.txt` conté les URL de les imatges a processar. Per exemple:



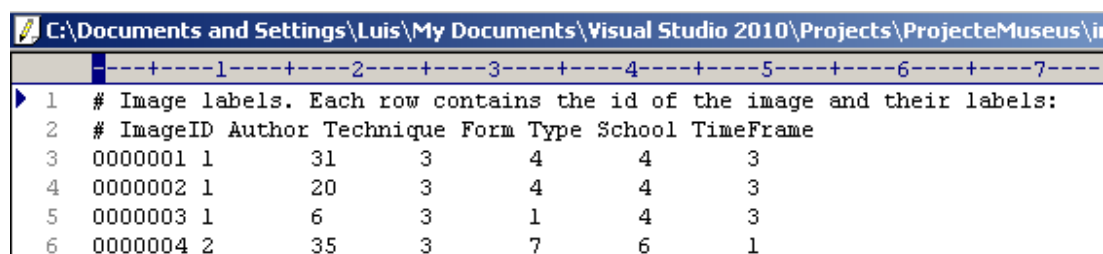
```

C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\ProjecteMuseus\url.txt
1 # Image url. Each row contains the id of the image and their url:
2 0000001 http://www.wqa.hu/art/a/aachen/allegory.jpg
3 0000002 http://www.wqa.hu/art/a/aachen/bacchus.jpg
4 0000003 http://www.wqa.hu/art/a/aachen/i_couple.jpg

```

Il·lustració 10 Exemple fitxer url.txt

- el fitxer `labels.txt` ens dóna els valors dels atributs de les obres d'art incloses a `url.txt`. Per exemple:



```

C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\ProjecteMuseus\labels.txt
1 # Image labels. Each row contains the id of the image and their labels:
2 # ImageID Author Technique Form Type School TimeFrame
3 0000001 1 31 3 4 4 3
4 0000002 1 20 3 4 4 3
5 0000003 1 6 3 1 4 3
6 0000004 2 35 3 7 6 1

```

Il·lustració 11 Exemple fitxer labels.txt

La classificació del conjunt d'imatges ha de ser per a un atribut determinat dels disponibles. Els atributs que considerem són:

- 1: autor
- 2: tècnica
- 3: format de l'obra
- 4: tipus d'obra d'art
- 5: escola
- 6: període

Aquests atributs tindran un conjunt discret de valors que defineixen una partició del conjunt en classes. Al conjunt d'imatges caldrà que tinguem el mateix nombre d'elements de cada classe. A l'hora de classificar aquest conjunt ens caldrà donar els següents paràmetres:

- ❑ Directori arrel on es troben els fitxers descriptors de les imatges
- ❑ Nombre de *folds* que volem construir
- ❑ Nombre d'obres d'art que hi ha a cada classe
- ❑ Atribut que volem analitzar

### **3.2. Procediment pas a pas**

L'execució del programari per a un conjunt d'imatges determinat fa les etapes següents:

1. Processament del conjunt d'imatges especificat. La imatge es descarrega a la carpeta local si no hi era abans.
2. Per cada imatge instanciem un objecte del tipus obra d'art en què tenim la imatge digitalitzada, la seva classe i els 3 histogrames de color.
3. Classifiquem aleatòriament les imatges de les obres d'art en  $k$  *folds* on cada *fold* té  $n$  elements de cada classe. Els valors de  $k$  i  $n$  estan determinats. El nombre total d'elements és  $k*n*c$  on  $c$  és el nombre de classes que tenim.
4. Apliquem *K fold cross validation* agafant un *fold* diferent com a conjunt de test per a cada iteració. A cada iteració obtenim els elements del conjunt de test ben classificats.
5. La bondat final de la classificació es el promig de les  $k$  iteracions.

### **3.3. Resultat esperat**

La bondat final de la classificació es el promig de les  $k$  iteracions.

## 4. Disseny tècnic

### 4.1. Primer nivell d'anàlisi descendent

El programari ha estat desenvolupat en C++ fent servir les llibreries d'OpenCV v.2.3.1 pel tractament d'imatges. L'entorn IDE utilitzat ha estat Microsoft Visual Studio 2011. Així doncs, el programari consisteix en un projecte Visual Studio anomenat **ProjecteMuseus**.

Implementarem una classe **classificador** llur constructor tindrà els següents paràmetres:

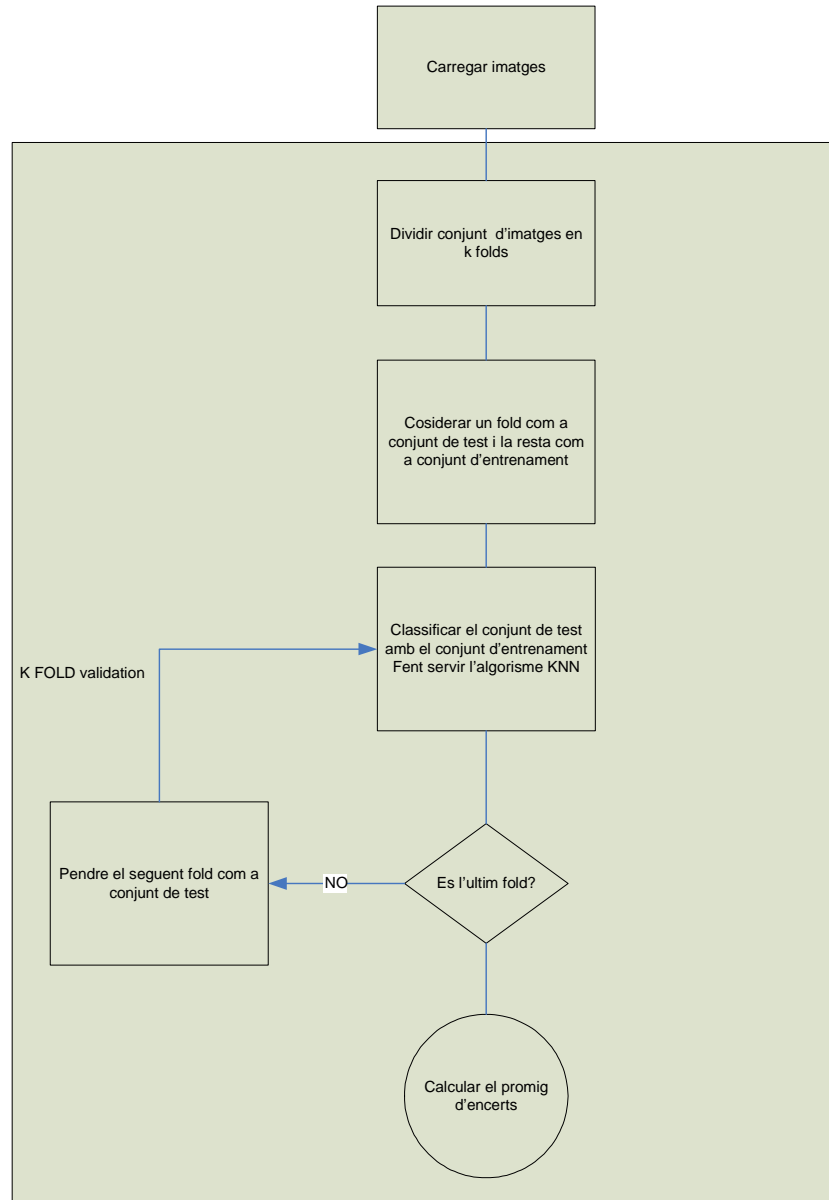
Nom	Tipus	contingut
dbPath	String	Director on es troben les dades del conjunt d'imatges
p_num_folds	Integer	Nombre de <i>folds</i> que volem construir
p_num_class_per_fold	Integer	Nombre d'obres d'art que hi han a cada classe
p_feature_type	Integer	Identificador de l'atribut que fem servir com a classificador  1: autor  2: tècnica  3: format de l'obra  4: tipus d'obra d'art  5: escola  6: període
p_debug	Boolean	Si és cert genera un log detallat de tot els càlculs realitzats
Valor_K	Integer	Valor de K per l'algorisme K-NN

**Taula 3** Paràmetres del constructor classe **Classificador**

Aquesta classe tindrà, a part del constructor i el destructor, un sol mètode públic **run()** que executa la classificació.



Al primer nivell d'anàlisi descendent, el procediment a implementar per la classe **classificador** ve determinat pel diagrama de blocs següent.



Il·lustració 12 Anàlisi descendent: primer nivell

La càrrega d'imatges s'implementa en el mètode constructor, i la resta de funcionalitats s'executen dins del mètode **run()**.

## 4.2. Segon nivell d'anàlisi descendent

En aquest nivell especifiquem les funcionalitats a implementar en el mètode constructor de la classe classificador i en el mètode `run()`.

### El mètode constructor

```

Classificador::Classificador(string dbPath, int p_num_folds, int p_num_class_per_fold,
int p_feature_type, bool p_debug)
{
    m_num_folds = p_num_folds;
    m_num_class_per_fold = p_num_class_per_fold;
    m_debug = p_debug;
    CDadesMuseus dm(dbPath, p_feature_type);
    dm.setLocalStoragePath(dbPath.append("/local"));
    dm.setLocalStorage(true);
    setDM(dm);
}

```

Notem que aquest mètode, a més de carregar els paràmetres de la classificació en variables d'instància, com per exemple el nombre de *folds*, etc., instancia un objecte de la classe **CDadesMuseus** i el desa a una variable d'instància d'aquest tipus. Aquest objecte és l'encarregat d'accedir als fitxers que defineixen el conjunt d'imatges de les obres d'art i generar un vector d'objectes de tipus **Obra**. Un objecte de tipus **Obra** conté la informació d'una d'aquestes imatges: la imatge digitalitzada en una matriu, els histogrames, els valors dels atributs, així com mètodes per a mostrar les imatges i els histogrames, i per calcular la "distància" amb d'altres objectes d'aquest tipus. Aquesta distància, com veurem més endavant, està basada en la comparació d'histogrames.

### El mètode run()

Aquest mètode realitza la classificació del conjunt d'imatges.

```

// inici de la classificacio: calcul dels folds
spliIntoFolds();
if (m_debug) {showFolds();};

int bondat = 0;
for (int ii=1; ii<=getNumFolds(); ii++) {

    // k-fold iter ii
    cout << "-----" << endl;
    cout << "Iteracio #"; cout << ii<< endl;
    setTestSet(ii);
    if (m_debug) {showTrainingAndTestSets();};
    classifyTestSet();
    bondat += showResult(false);
}
bondat = bondat/getNumFolds();

cout << "-----" << endl;
cout << "El promig dels "; cout << getNumFolds() ; cout << " folds es: "; cout << bondat;
cout << " %."<< endl;
cout << "-----" << endl;

```

Inicialment es divideixen aleatòriament els elements del conjunt en *folds*. Això passa en la crida al mètode `splitIntoFolds()`.

Un cop tenim els *folds* definits, s'implementa l'algorisme de *K-fold Cross-Validation* (veure detalls en el següent apartat 4.3) i es mostren els resultats.

### 4.3. Algorisme de validació de la classificació del conjunt d'aprenentatge

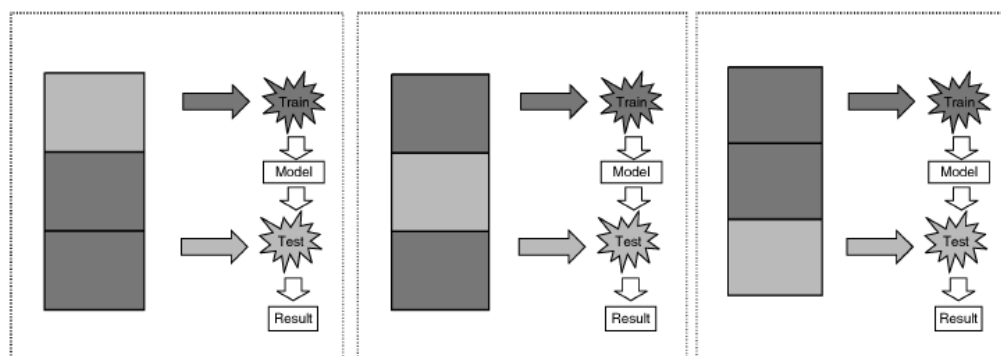
Per validar si un determinat conjunt d'entrenament pot servir per a classificar un conjunt d'obres d'art en base a la correlació entre els histogrames de les seves imatges, farem servir l'algorisme de validació creada conegut com *K-fold Cross-Validation* (veure <http://www.public.asu.edu/~ltang9/papers/ency-cross-validation.pdf>)

La validació creuada és un mètode estadístic per avaluar els algorismes d'aprenentatge, consistent en la divisió de les dades en dos segments: un s'utilitza per aprendre o entrenar un model i l'altre per validar el model. En la validació creuada, els conjunts d'entrenament i de validació s'intercanvien en rondes successives de manera que cadascuna de les dades té l'oportunitat de ser validada i validadora.

La *K-fold Cross-Validation* equival a  $k$  vegades la validació creuada. Les dades és divideixen en  $k$  parts iguals (o gairebé iguals). Posteriorment es realitzen  $k$  iteracions d'entrenament i validació de tal manera que a cada iteració porta a terme la validació un conjunt diferent de les dades, mentre que la resta de  $k-1$  conjunts s'utilitzen per a l'aprenentatge.

Al final tenim  $k$  mostres de la mètrica de rendiment que en promig donen l'avaluació de l'algorisme d'aprenentatge aplicat a un cas concret.

En el nostre cas, volem avaluar la validesa de l'algorisme de classificació KNN aplicat a la classificació d'obres d'art mitjançant la comparació dels 3 histogrames RGB.



Il·lustració 13 Procediment 3-fold cross validation

#### 4.4. Algorisme de classificació

Farem servir com algorisme de classificació el k-NN. El *K-nearest neighbors* (k-NN) és un algorisme per a la classificació que traduït al català vindria a significar els K veïns més pròxims. El mètode classifica els exemples segons la seva proximitat als exemples d'entrenament en l'espai de característiques, és a dir, l'espai que inclou tots els exemples possibles. És un dels algorismes d'aprenentatge automàtic més simples. Funciona de la manera següent:

- Primer comprovarem quins són els K exemples d'entrenament més pròxims a l'objecte a classificar i aleshores comptarem a quines classes pertanyen.
- La classe que tingui més exemples d'entrenament propers a l'objecte a classificar determinarà la classe resultant.

Per a determinar quins són els exemples més pròxims normalment s'utilitza la distància Euclidiana. No obstant això, com que la característica que volem comparar són els histogrames, hem de definir una noció de distància entre ells. A la llibreria openCV tenim un mètode per comparar histogrames amb la signatura següent:

```
double cvCompareHist(const CvHistogram* hist1,
                    const CvHistogram* hist2,
                    int method)
```

(veure <http://opencv.willowgarage.com/documentation/histograms.html> - cvCompareHist )

Els mètodes disponibles per calcular la distància són 4:

- ❑ CV\_COMP\_CORREL – Correlation. S'aplica la fórmula

$$d(H_1, H_2) = \frac{\sum_I (H'_1(I) \cdot H'_2(I))}{\sqrt{\sum_I (H'_1(I)^2) \cdot \sum_I (H'_2(I)^2)}}$$

$$H'_k(I) = \frac{H_k(I) - 1}{N \cdot \sum_J H_k(J)}$$

- ❑ CV\_COMP\_CHISQR - Chi-Square. S'aplica la fórmula

$$d(H_1, H_2) = \sum_I \frac{(H_1(I) - H_2(I))^2}{H_1(I) + H_2(I)}$$

- CV\_COMP\_INTERSECT – Intersection

$$d(H_1, H_2) = \sum_I \min(H_1(I), H_2(I))$$

- CV\_COMP\_BHATTACHARYYA - Bhattacharyya distance

$$d(H_1, H_2) = \sqrt{1 - \sum_I \frac{\sqrt{H_1(I) \cdot H_2(I)}}{\sqrt{\sum_I H_1(I) \cdot \sum_I H_2(I)}}}$$

En aquestes formules  $H_1$  denota el primer histograma i  $H_2$  el segon. El mètode CV\_COMP\_BHATTACHARYYA solament s'aplica a histogrames normalitzats. En aquest projecte treballarem amb histogrames normalitzats.

## 4.5. Funcions utilitzades d'OpenCV

En aquest projecte hem utilitzat les funcions d'Open CV següents:

### □ Càrrega d'imatges

Un cop tenim les imatges desades en una carpeta local del PC, fem servir la funció `imread()` per carregar una imatge en una matriu

```
// Read the image from the local storage path
Mat image;
image=imread(fullFileName);
if(!image.empty()) {
    imageLoaded=true;
}
```

### □ Generació d'histogrames

Calcularem els histogrames RGB d'una imatge determinada fent servir la funció `calcHist()`. També ens caldrà fer servir la funció `split()` per dividir una imatge en els seus components RGB i la funció `normalize()` per normalitzar l'histograma.

```
Mat src, dst;

/// Load image
src = m_image;

// Separate the image in 3 places ( R, G and B )
vector<Mat> rgb_planes;
split( src, rgb_planes );

/// Establish the number of bins
int histSize = 256;

/// Set the ranges ( for R,G,B )
float range[] = { 0, 255 };
const float* histRange = { range };

// Compute the histograms
bool uniform = true; bool accumulate = false;
calcHist( &rgb_planes[0], 1, 0, Mat(), b_hist, 1, &histSize, &histRange, uniform,
accumulate );
calcHist( &rgb_planes[1], 1, 0, Mat(), g_hist, 1, &histSize, &histRange, uniform,
accumulate );
calcHist( &rgb_planes[2], 1, 0, Mat(), r_hist, 1, &histSize, &histRange, uniform,
accumulate );

// Normalize the result to [ 0, 400]
int hist_w = 400;
normalize(r_hist, r_hist, 0, hist_w, NORM_MINMAX, -1, Mat() );
normalize(g_hist, g_hist, 0, hist_w, NORM_MINMAX, -1, Mat() );
normalize(b_hist, b_hist, 0, hist_w, NORM_MINMAX, -1, Mat() );
```

□ Comparació d'histogrames

En la classe `Obra` que modelitza una obra d'art definim un mètode anomenat `distància()`

```
double Obra::distància(Obra obr)
```

que calcula la distància amb una altra `Obra` passada per paràmetres. La distància es calcula fent servir la funció `compareHist()` d'OpenCv


```
double resultat = compareHist(r_hist, obr.getHist_r(), 1) +  
compareHist(g_hist, obr.getHist_g(), 1) +  
compareHist(b_hist, obr.getHist_b(), 1) ;
```

## 5.Documentació tècnica

En aquest capítol s'especifiquen tècnicament els lliurables del projecte.

### 5.1. Estructura de carpetes

El projecte `\ProjecteMuseus` ha estat desenvolupat amb C++ fent servir MS Visual Studio 2010. Per això té l'estructura de carpetes típica d'aquests projectes:



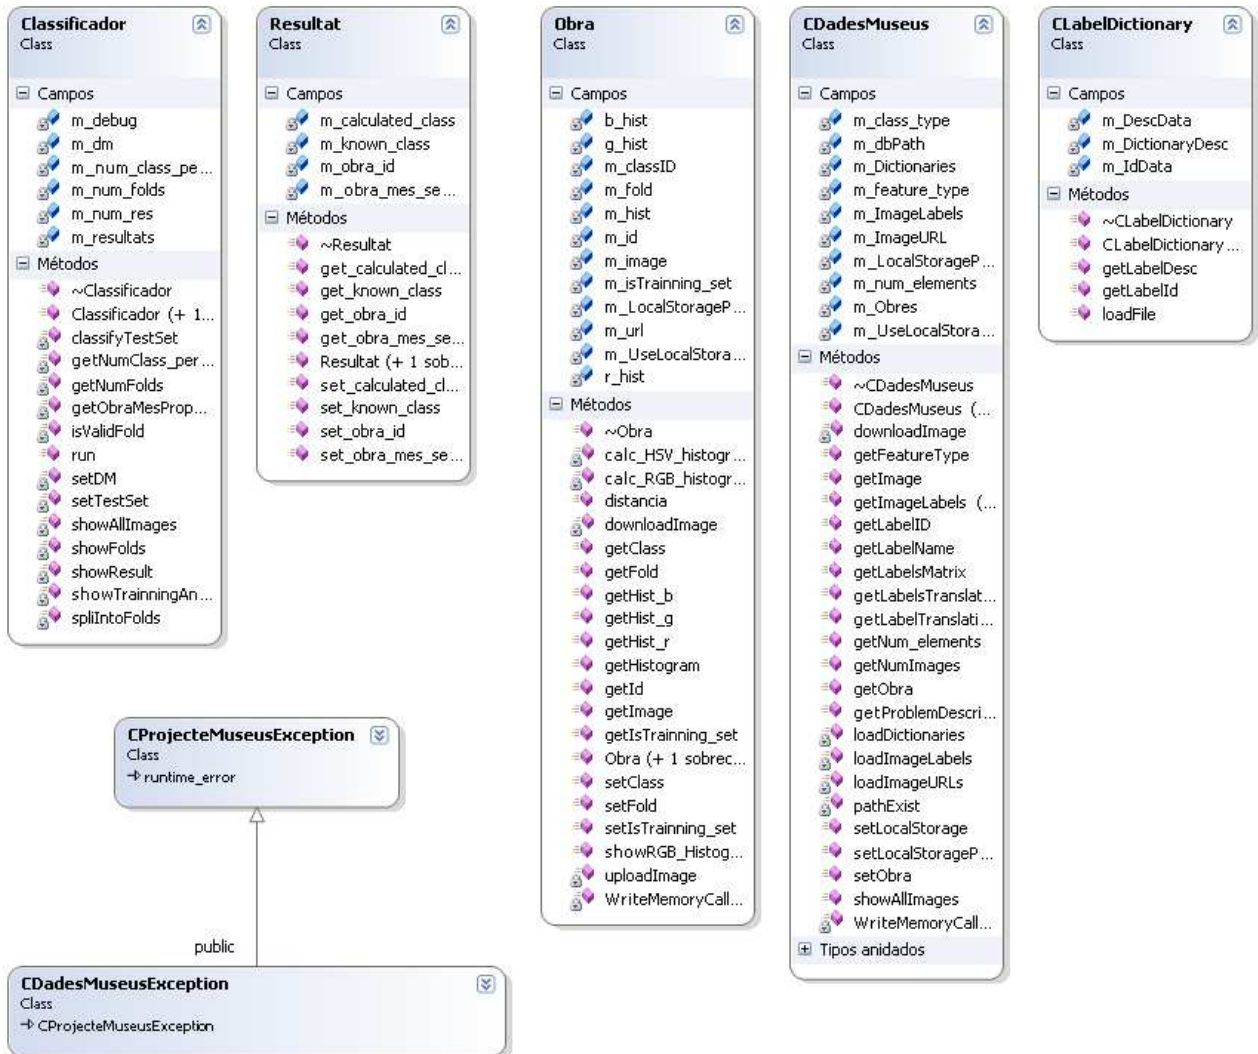
Il·lustració 14 Estructura projecte ProjecteMuseus

<code>ProjecteMuseus</code>	Carpeta Arrel del projecte
+ -- <code>Debug</code>	
+ -- <code>Release</code>	Executable final del projecte
+ -- <code>Ipch</code>	
+ -- <code>ProjecteMuseus</code>	Codi font
+ -- <code>images_case1</code>	Carpeta amb imatges locals pel cas1
+ -- <code>extern</code>	Llibreries d'open CV



## 5.2. Diagrama de classes

A continuació tenim les classes que configuren el projecte ProjecteMuseus



Il·lustració 15 Diagrama de classes del projecte

### ProjecteMuseus.cpp

Classe inicial del projecte que implementa el mètode `_tmain()`. Aquesta classe crea una instància de la classe `Classificador` passant com a paràmetres els paràmetres d'entrada.

```
char * _path = new char [100];
_path = (char *) argv[1];
char * _folds = new char [1];
_folds = (char *) argv[2];
char * _class_elements = new char [1];
_class_elements = (char *) argv[3];
char * _atribut = new char [1];
_atribut = (char *) argv[4];
char * _debug = new char [1];
_debug = (char *) argv[5];
bool _debug_bool = false;
if (strcmp(_debug, "1")) { bool _debug_bool = true; }

Classificador clf1(_path, atoi(_folds), atoi(_class_elements), atoi(_atribut),
    _debug_bool);
clf1.run();
```

### Classificador.cpp

Classe que implementa el procés de validació de la bondat del classificador com ja s'ha detallat a l'apartat 4.2.

### CDadesMuseus.cpp

Classe que implementa la càrrega i digitalització de les imatges de les obres d'art.

### Obra.cpp

Classe que modelitza una obra d'art. Inclou el mètode `distància` per calcular la seva distància amb una altra obra d'art. En el nostre cas es fa comparant histogrames amb l'ajut de les funcions d'OpenCV.

### 5.3. Execució

Per executar el classificador cal fer una crida al programa **ProjecteMuseus** amb els paràmetres esperats.

Nom	Tipus	Contingut
p_Path	String	Directorí arrel on es troben les dades del conjunt d'imatges
p_num_folds	Integer	Nombre de <i>folds</i> que volem construir
p_num_class_per_fold	Integer	Nombre d'obres d'art que hi ha a cada classe
p_feature_type	Integer	Identificador de l'atribut que fem servir com a classificador 1: autor 2: tècnica 3: format de l'obra 4: tipus d'obra d'art 5: escola 6: període
p_debug	Integer	Si és cert genera un log detallat de tots els càlculs realitzats 1 vol dir "true"
K_num		Valor K de l'algorisme KNN

Taula 4 Paràmetres de la crida al programa ProjecteMuseus.exe

Exemple:

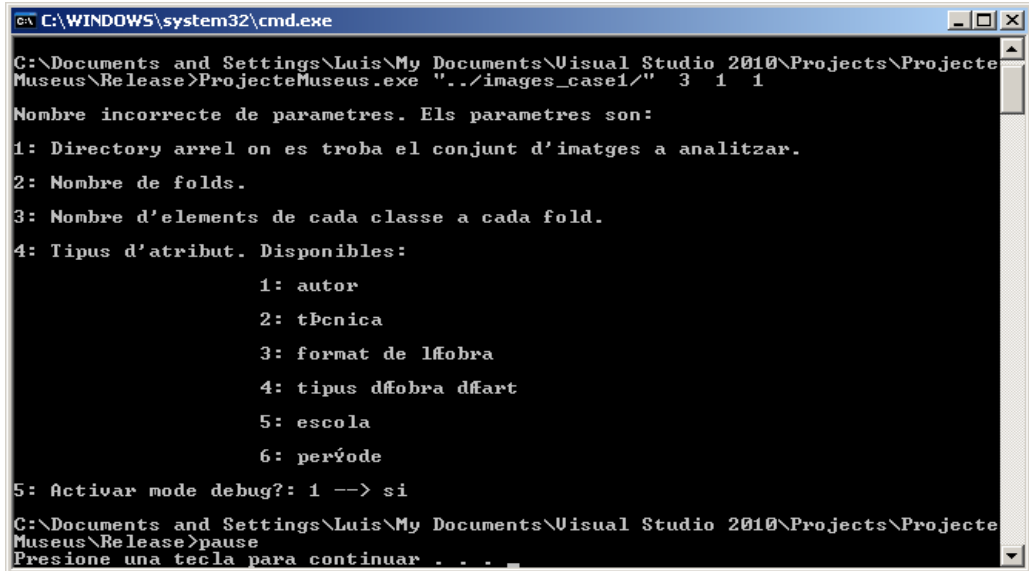
```
ProjecteMuseus.exe "../images_case1/" 3 1 1 0 1
```

Perquè funcioni correctament, el directori actual ha de ser la carpeta "release" del directori arrel del projecte. Podem crear un fitxer bat situat al directori arrel del projecte, amb el contingut següent:

```
cd Release
```

```
ProjecteMuseus.exe "../images_case1/" 3 1 1 0 1
```

En cas d'un nombre incorrecte de paràmetres, es mostra un missatge informatiu:



```
C:\WINDOWS\system32\cmd.exe
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_case1/" 3 1 1
Nombre incorrecte de parametres. Els parametres son:
1: Directory arrel on es troba el conjunt d'imatges a analitzar.
2: Nombre de folds.
3: Nombre d'elements de cada classe a cada fold.
4: Tipus d'atribut. Disponibles:
    1: autor
    2: tÈcnica
    3: format de llibre
    4: tipus d'obra d'art
    5: escola
    6: període
5: Activar mode debug?: 1 --> si
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>pause
Presione una tecla para continuar . . .
```

Taula 5 Sortida del programa quan el nombre d'argument és incorrecte

## 6. Proves i resultats

En aquest capítol s'especifiquen les proves realitzades per verificar el funcionament correcte dels lliurables del projecte. També es detalla el resultat de l'aplicació dels lliurables generats a l'anàlisi de la viabilitat de la classificació d'obres d'art mitjançant l'anàlisi dels seus histogrames.

### 6.1. Proves realitzades

Per a validar el funcionament correcte del programari de classificació, considerarem uns casos el resultat dels quals és senzill de preveure.

#### Cas 1: Dupliquem les imatges – 100% encert esperat

Tenim el següent conjunt d'autors:

Id classe	Nom del autor
00001	AACHEN, Hans von
00002	ABADIA, Juan de la
00003	ABAQUESNE, Masséot
00004	ABBATE, Niccolò dell'
00005	ABILDGAARD, Nicolai

Taula 6 Llista d'autors del Cas 1

#### Condicció prèvia:

Considerarem el grup d'imatges d'obres d'art format per 2 obres d'art de cadascun dels 5 autors:

Id classe	Id obra
1	0000001 0000002
2	0000003 0000004
3	0000005 0000006
4	0000007 0000008
5	0000009 0000010

Taula 7 Llista d'obres del Cas 1

De tal manera que les 2 obres d'art de cada autor són la mateixa. És a dir, el fitxer **url.txt** és

```
# Image url. Each row contains the id of the image and their url:
0000001 http://www.wqa.hu/art/a/aachen/allegory.jpg
0000002 http://www.wqa.hu/art/a/aachen/allegory.jpg
0000003 http://www.wqa.hu/art/a/abadia/michael.jpg
0000004 http://www.wqa.hu/art/a/abadia/michael.jpg
0000005 http://www.wqa.hu/art/a/abaquesn/albarell.jpg
0000006 http://www.wqa.hu/art/a/abaquesn/albarell.jpg
0000007 http://www.wqa.hu/art/a/abbate/chimnevl.jpg
0000008 http://www.wqa.hu/art/a/abbate/chimnevl.jpg
0000009 http://www.wqa.hu/art/a/abildqaa/culminqh.jpg
0000010 http://www.wqa.hu/art/a/abildqaa/culminqh.jpg
```

Il·lustració 16 Cas1: fitxer url.txt

I el fitxer és **labels.txt**

```
# Image labels. Each row contains the id of the image and their labels
# ImageID Author Technique Form Type School TimeFrame
0000001 1 0 0 0 0 0
0000002 1 0 0 0 0 0
0000003 2 0 0 0 0 0
0000004 2 0 0 0 0 0
0000005 3 0 0 0 0 0
0000006 3 0 0 0 0 0
0000007 4 0 0 0 0 0
0000008 4 0 0 0 0 0
0000009 5 0 0 0 0 0
0000010 5 0 0 0 0 0
```

Il·lustració 17 Cas1: fitxer labels.txt

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_test1** dintre del directori arrel del projecte.

**Resultat del Test**

Acció	Resultat esperat	Resultat														
<p>Fem que el directori actual sigui el directori arrel del projecte.</p> <p>Fem <code>cd Release</code></p> <p>Fem la crida al programa <code>ProjecteMuseus.exe</code> amb els paràmetres següents:</p> <table border="1" data-bbox="233 692 809 1169"> <thead> <tr> <th>parametre</th> <th>valor</th> </tr> </thead> <tbody> <tr> <td>p_Path</td> <td>../images_test1/</td> </tr> <tr> <td>p_num_folds</td> <td>2</td> </tr> <tr> <td>p_num_class_per_fold</td> <td>1</td> </tr> <tr> <td>p_feature_type</td> <td>1 (= autor)</td> </tr> <tr> <td>P_debug</td> <td>0= fals</td> </tr> <tr> <td>K_value</td> <td>KNN amb K=1 Ja que el conjunt d'elements és tan petit</td> </tr> </tbody> </table> <p>És a dir, volem tenir 2 <i>folders</i> i cada <i>fold</i> tindrà 1 element de cada classe.</p> <pre>ProjecteMuseus.exe "../images_test1/" 2 1 1 0 1</pre> <p>Trobem el resultat de la classificació obtingut per la consola de MSDOS.</p>	parametre	valor	p_Path	../images_test1/	p_num_folds	2	p_num_class_per_fold	1	p_feature_type	1 (= autor)	P_debug	0= fals	K_value	KNN amb K=1 Ja que el conjunt d'elements és tan petit	<p>El primer cop que s'executa la carpeta local està buida. Llavors té lloc la descàrrega de les imatges des de les seves urls cap aquesta carpeta (veure il·lustració 18). Les següents execucions ja trobaran aquí les imatges i no les descarregaran (veure il·lustració 19 on es mostren les imatges ja descarregades).</p> <p>El procés de classificació comença per dividir les 10 imatges en 2 <i>folders</i>, de manera que cada <i>fold</i> conté 1 element de cada classe (veure il·lustració 20 quadre A).</p> <p>A continuació realitzem 2 iteracions, en la primera iteració el <i>fold</i> #1 és el conjunt de test i el <i>fold</i> #2 el d'entrenament. En la segona intercanviem els papers. L'encert es del 100% perquè com que les imatges de cada classe estan duplicades, la correspondència entre els conjunts de test i d'entrenament és sempre del 100%. (veure il·lustració 20 quadre B).</p> <p>El resultat final calculat com el promig de les 2 iteracions és de 100% (veure il·lustració 20 quadre C).</p>	<p>OK</p>
parametre	valor															
p_Path	../images_test1/															
p_num_folds	2															
p_num_class_per_fold	1															
p_feature_type	1 (= autor)															
P_debug	0= fals															
K_value	KNN amb K=1 Ja que el conjunt d'elements és tan petit															

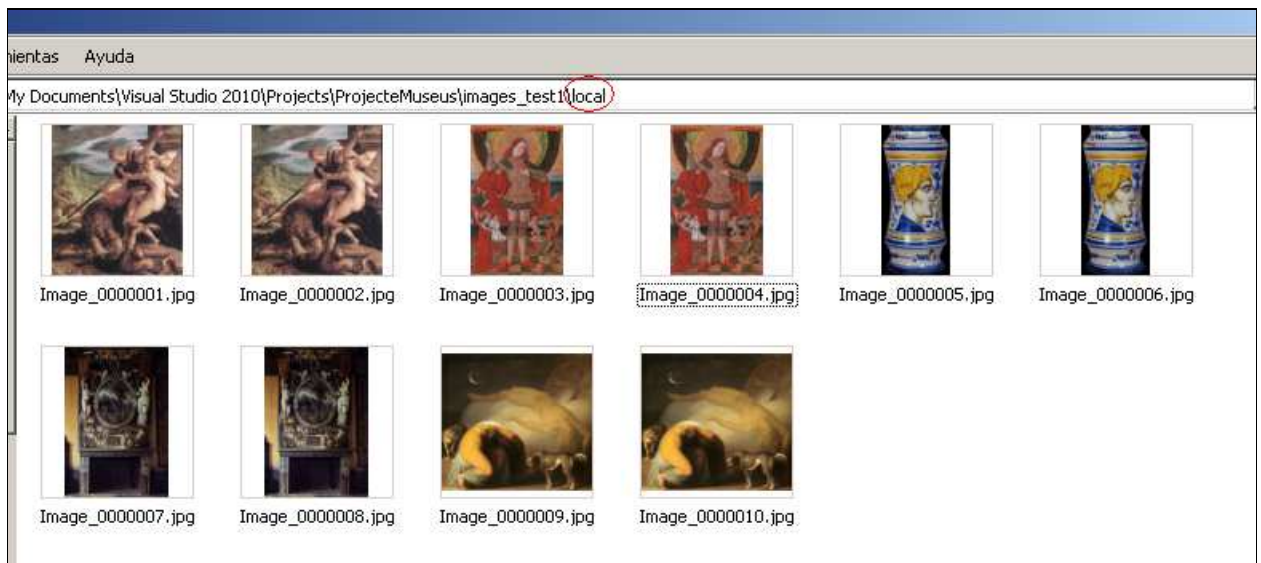
**Taula 8 Resultats test 1**

```

C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\ProjecteMuseus\Debug...
< Content-Length: 109312
< Date: Thu, 29 Dec 2011 18:48:45 GMT
< Server: lighttpd/1.4.19
<
* Connection #0 to host www.wga.hu left intact
* Closing connection #0
* About to connect() to www.wga.hu port 80 (#0)
* Trying 148.6.0.90... * connected
* Connected to www.wga.hu (148.6.0.90) port 80 (#0)
> GET /art/a/aachen/allegory.jpg HTTP/1.1
Host: www.wga.hu
Accept: */*

< HTTP/1.1 200 OK
< Content-Type: image/jpeg
< Accept-Ranges: bytes
< ETag: "3049168320"
< Last-Modified: Sat, 21 Sep 2002 16:01:56 GMT
< Content-Length: 109312
< Date: Thu, 29 Dec 2011 18:48:47 GMT
< Server: lighttpd/1.4.19
<
* Connection #0 to host www.wga.hu left intact
* Closing connection #0
    
```

Il·lustració 18 Descàrrega de les imatges a la carpeta local.



Il·lustració 19 Contingut carpeta local un cop descarregades les imatges



```

C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe    "../images_test1/"    2    1
1
-----
Nombre d'elements trobats:10
Conjunt de dades dividit en 2 folds.
El Fold 1 hi tenim: 2, 3, 5, 8, 10,
El Fold 2 hi tenim: 1, 4, 6, 7, 9,
-----
Iteracio #1
-----
Conjunt d'entrenament: 1, 4, 6, 7, 9,
Conjunt de Test: 2, 3, 5, 8, 10,
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 5
Total Errors : 0
Bondat (<%) : 100
-----
Iteracio #2
-----
Conjunt d'entrenament: 2, 3, 5, 8, 10,
Conjunt de Test: 1, 4, 6, 7, 9,
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 5
Total Errors : 0
Bondat (<%) : 100
-----
El promig dels 2 folds es: 100 %.
-----
Prem una tecla per continuar...

```

Il·lustració 20 Resultat de la classificació

## Cas 2: Dupliquem les imatges però en les còpies canviem l'autor (esperem un 0% d'encert)

Mantenim el fitxer `url.txt` del cas anterior, però ara el fitxer `labels.txt` és

```

# Image labels. Each row contains the id of the image and their labels:
# ImageID Author Technique Form Type School TimeFrame
0000001 1 0 0 0 0 0
0000002 5 0 0 0 0 0
0000003 2 0 0 0 0 0
0000004 4 0 0 0 0 0
0000005 3 0 0 0 0 0
0000006 1 0 0 0 0 0
0000007 4 0 0 0 0 0
0000008 2 0 0 0 0 0
0000009 5 0 0 0 0 0
0000010 3 0 0 0 0 0

```

Il·lustració 21 Cas2: fitxer labels.txt

Notem que ara les imatges duplicades tenen una classe diferent (= autor)!

**Resultat del Test**

Acció	Resultat esperat	Resultat														
<p>Fem que el directori actual sigui el directori arrel del projecte.</p> <p>Fem <code>cd Release</code></p> <p>Fem la crida amb els paràmetres següents:</p> <table border="1" data-bbox="233 786 809 1261"> <thead> <tr> <th>Parametre</th> <th>valor</th> </tr> </thead> <tbody> <tr> <td>p_Path</td> <td>../images_test2/</td> </tr> <tr> <td>p_num_folds</td> <td>2</td> </tr> <tr> <td>p_num_class_per_fold</td> <td>1</td> </tr> <tr> <td>p_feature_type</td> <td>1 (= autor)</td> </tr> <tr> <td>P_debug</td> <td>1= cert</td> </tr> <tr> <td>K_value</td> <td>KNN amb K=1 Ja que el conjunt d'elements és tan petit</td> </tr> </tbody> </table> <p>És a dir, volem tenir 2 <i>folders</i> i cada <i>fold</i> tindrà 1 element de cada classe.</p> <pre>ProjecteMuseus.exe "../images_test2/" 2 1 1 1 1</pre> <p>Trobem el resultat de la classificació obtingut per la consola de MSDOS.</p>	Parametre	valor	p_Path	../images_test2/	p_num_folds	2	p_num_class_per_fold	1	p_feature_type	1 (= autor)	P_debug	1= cert	K_value	KNN amb K=1 Ja que el conjunt d'elements és tan petit	<p>Igual que al cas anterior, però ara el percentatge d'encert serà <b>0%</b> ja que hem canviat intencionadament la classe (autor) de les obres d'art, de tal manera que les obres d'art que eren iguals ara tenen autors diferents.</p> <p>Com que hem activat el mode <i>debug</i> ara tenim més informació del procés de classificació (veure il·lustració 22). En particular sabem quina obra ha estat calculada com a obra veïna més propera (classificació 1NN).</p> <p>A la figura s'observa que dóna una bondat (% d'encert) del 0% previst.</p>	<p>OK</p>
Parametre	valor															
p_Path	../images_test2/															
p_num_folds	2															
p_num_class_per_fold	1															
p_feature_type	1 (= autor)															
P_debug	1= cert															
K_value	KNN amb K=1 Ja que el conjunt d'elements és tan petit															

Taula 9 Resultats test 2

```

-----
Nombre d'elements trobats:10
-----
Conjunt de dades dividit en 2 folds.
-----
Al Fold 1 hi tenim: 3, 4, 6, 9, 10,
-----
Al Fold 2 hi tenim: 1, 2, 5, 7, 8,
-----
Iteracio #1
-----
Conjunt d'entrenament: 1, 2, 5, 7, 8,
Conjunt de Test: 3, 4, 6, 9, 10,
-----
Resultat de la classificacio del conjunt de test:
-----
Obra:3
Obra mes semblant:1
Classe Real:2
Classe Calculada:1
-----
Obra:4
Obra mes semblant:1
Classe Real:4
Classe Calculada:1
-----
Obra:6
Obra mes semblant:5
Classe Real:1
Classe Calculada:3
-----
Obra:9
Obra mes semblant:1
Classe Real:5
Classe Calculada:1
-----
Obra:10
Obra mes semblant:1
Classe Real:3
Classe Calculada:1
Total Encerts: 0
Total Errors : 5
Bondat (%) : 0
-----
Iteracio #2
-----
Conjunt d'entrenament: 3, 4, 6, 9, 10,
Conjunt de Test: 1, 2, 5, 7, 8,
-----
Resultat de la classificacio del conjunt de test:
-----
Obra:1
Obra mes semblant:3
Classe Real:1
Classe Calculada:2
-----
Obra:2
Obra mes semblant:3
Classe Real:5
Classe Calculada:2
-----
Obra:5
Obra mes semblant:6
Classe Real:3
Classe Calculada:1
-----
Obra:7
Obra mes semblant:9
Classe Real:4
Classe Calculada:5
-----
Obra:8
Obra mes semblant:9
Classe Real:2
Classe Calculada:5
Total Encerts: 0
Total Errors : 5
Bondat (%) : 0
-----
El promig dels 2 folds es: 0 %.
-----
Prem una tecla per continuar...

```

### II·lustració 22 Resultat de la classificació – mode debug activat

Amb les proves realitzades tenim confiança que el programa funciona correctament. A continuació l'aplicarem per analitzar el comportament de les classificacions basades en histogrames pels diferents tipus d'atribut que tenim.

## 6.2. Aplicació: Classificació per l'atribut "format"

Recordem que l'atribut "format de l'obra" tindrà una sèrie de valors possibles (classes):

Atribut	Nombre de valors
<b>Form</b>	00001 ceramics
	00002 graphics
	00003 painting
	00004 sculpture

Taula 10 Llista de forms

Ara aplicarem el *software* generat a l'anàlisi de la viabilitat de la classificació d'obres d'art segons el seu format mitjançant l'anàlisi dels histogrames.

### Execució número #1

Considerarem el grup d'imatges d'obres d'art format per 4 elements de cada classe:

Id classe	Id obra
1	0000001 0000002 0000003 0000004
2	0000005 0000006 0000007 0000008
3	0000009 0000010 0000011 0000012
4	0000013 0000014 0000015 0000016

Taula 11 Llista d'obres de la execució #1

El fitxer `url.txt` és

```
# Image url. Each row contains the id of the image and their url:
0000001 http://www.wqa.hu/art/a/abaquesn/albarell.jpg
0000002 http://www.wqa.hu/art/a/abaquesn/floor1.jpg
0000003 http://www.wqa.hu/art/a/abaquesn/floor2.jpg
0000004 http://www.wqa.hu/art/a/abaquesn/theflood.jpg
0000005 http://www.wqa.hu/art/a/abildqaa/z\_adamev.jpg
0000006 http://www.wqa.hu/art/a/adam/lambert/selfport.jpg
0000007 http://www.wqa.hu/art/a/arcimbol/6court/01sketch.jpg
0000008 http://www.wqa.hu/art/a/arcimbol/6court/03sketch.jpg
0000009 http://www.wqa.hu/art/a/aachen/allegory.jpg
0000010 http://www.wqa.hu/art/a/aachen/bacchus.jpg
0000011 http://www.wqa.hu/art/a/aachen/i\_couple.jpg
0000012 http://www.wqa.hu/art/a/abadia/michael.jpg
0000013 http://www.wqa.hu/art/a/adam/lambert/water.jpg
0000014 http://www.wqa.hu/art/a/adam/nicolas/martyrdo.jpg
0000015 http://www.wqa.hu/art/a/adam/nicolas/opalinsk.jpg
0000016 http://www.wqa.hu/art/a/adam/nicolas/opalinsx.jpg
```

Il·lustració 23 Execució #1: fitxer url.txt

I el fitxer **labels.txt** conté:

```
# Image labels. Each row contains the id of the image and their labels:
# ImageID Author Technique Form Type School TimeFrame
0000001 0 0 1 0 0 0
0000002 0 0 1 0 0 0
0000003 0 0 1 0 0 0
0000004 0 0 1 0 0 0
0000005 0 0 2 0 0 0
0000006 0 0 2 0 0 0
0000007 0 0 2 0 0 0
0000008 0 0 2 0 0 0
0000009 0 0 3 0 0 0
0000010 0 0 3 0 0 0
0000011 0 0 3 0 0 0
0000012 0 0 3 0 0 0
0000013 0 0 4 0 0 0
0000014 0 0 4 0 0 0
0000015 0 0 4 0 0 0
0000016 0 0 4 0 0 0
```

**Il·lustració 24 Execució #1: fitxer labels.txt**

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run1** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **4 folds**
- ❑ Cada *fold* amb **1** element de cada classe
- ❑ L'atribut "format" correspon al **#3**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

```
ProjecteMuseus.exe "../images_run1/" 4 1 3 0 1
```

El resultat es mostra a la Il·lustració 25. Notem com les imatges s'han descarregat en la carpeta local. Al log que surt a la consola veiem com s'han generat els 4 *fold*s correctament (amb 1 element de cada classe a cada *fold*). Notem que la precisió és dolenta però superior al cas aleatori (que és d'un 25% doncs tenim 4 valors equiprobables).

Si repetim la crida en mode debug

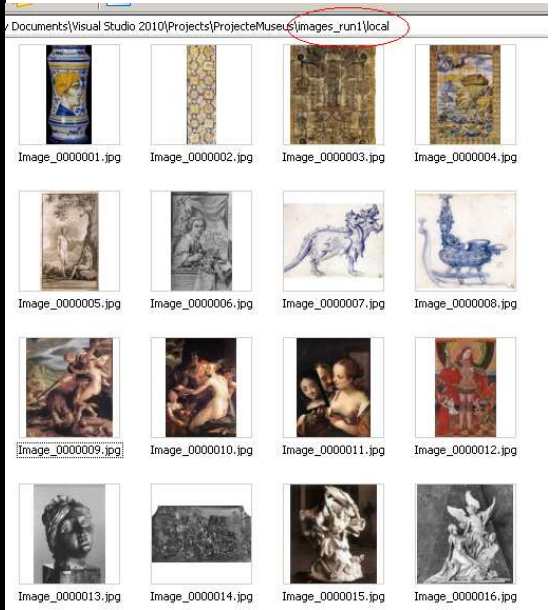
```
ProjecteMuseus.exe "../images_run1/" 4 1 3 1 1
```

Obtenim el detall de les classificacions, que ens ajudarà a entendre el desencert (veure a la Il·lustració 26 el detall de la classificació del *fold* #1).

```

C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe ".\images_run1/" 4 1 3 0 1
-----
Nombre d'elements trobats:16
-----
Conjunt de dades dividit en 4 folds.
Al Fold 1 hi tenim: 4, 6, 12, 14,
-----
Al Fold 2 hi tenim: 1, 5, 9, 16,
-----
Al Fold 3 hi tenim: 3, 7, 11, 15,
-----
Al Fold 4 hi tenim: 2, 8, 10, 13,
-----
Iteracio #1
Conjunt d'entrenament: 1, 2, 3, 5, 7, 8, 9, 10, 11, 13, 15, 16,
Conjunt de Test: 4, 6, 12, 14,
Resultat de la classificacio del conjunt de test:
Total Encerts: 2
Total Errors : 2
Bondat (%) : 50
-----
Iteracio #2
Conjunt d'entrenament: 2, 3, 4, 6, 7, 8, 10, 11, 12, 13, 14, 15,
Conjunt de Test: 1, 5, 9, 16,
Resultat de la classificacio del conjunt de test:
Total Encerts: 2
Total Errors : 2
Bondat (%) : 50
-----
Iteracio #3
Conjunt d'entrenament: 1, 2, 4, 5, 6, 8, 9, 10, 12, 13, 14, 16,
Conjunt de Test: 3, 7, 11, 15,
Resultat de la classificacio del conjunt de test:
Total Encerts: 2
Total Errors : 2
Bondat (%) : 50
-----
Iteracio #4
Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 9, 11, 12, 14, 15, 16,
Conjunt de Test: 2, 8, 10, 13,
Resultat de la classificacio del conjunt de test:
Total Encerts: 1
Total Errors : 3
Bondat (%) : 25
-----
El promig dels 4 folds es: 43 %.
-----
Prem una tecla per continuar...

```



II·lustració 25 Resultat execució #1 amb K=1

```


Iteracio #1
-----
Conjunt d'entrenament: 1, 2, 3, 5, 7, 8, 9, 10, 11, 13, 15, 16,
Conjunt de Test: 4, 6, 12, 14,
Resultat de la classificacio del conjunt de test:
-----
Obra:4
Obra mes semblant:3
Classe Real:1
Classe Calculada:1
-----
Obra:6
Obra mes semblant:9
Classe Real:2
Classe Calculada:3
-----
Obra:12
Obra mes semblant:9
Classe Real:3
Classe Calculada:3
-----
Obra:14
Obra mes semblant:9
Classe Real:4
Classe Calculada:3
Total Encerts: 2
Total Errors : 2
Bondat (%) : 50
-----

```


II·lustració 26 Resultat run1 amb K=1 en mode debug (classificació fold1)

El resultat de l'il·lustració 27 mostra que l'obra #4 ha estat ben classificada, perquè li ha estat assignada la obra #3 que és del mateix format. Mirant les imatges de la Il·lustració 28 veiem que a simple vista hi ha una aparent semblança de color entre ambdues imatges. Si comparem els histogrames (veure la il·lustració 29) notem una certa semblança: en ambdues tenim un predomini del color verd i vermell (major intensitat cap a la dreta dels histogrames), responsable d'aquest color groguenc de les imatges, encara que a la imatge #4 hi ha un major predomini dels blaus.

Imatge #3



Imatge #4



Il·lustració 27 Comparació dels histogrames de les imatges #3 i #4

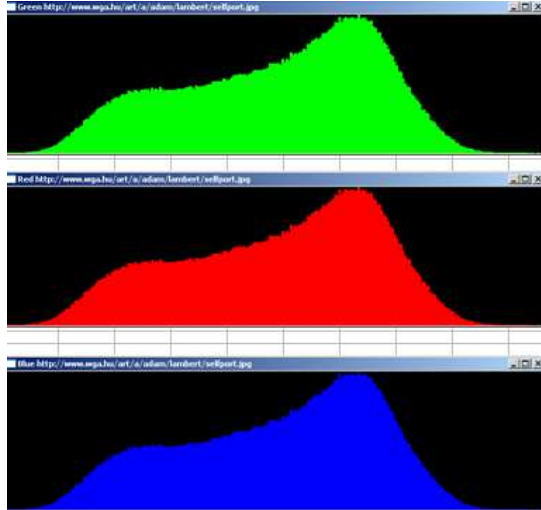
Notem que les obres que estan mal classificades són les que corresponen a figures en B/N. Les imatges en BN es caracteritzen perquè els histogrames RGB de cada color són iguals. Vegeu per exemple, els histogrames de les imatges #6 i #13 de la Il·lustració 28 de la pàgina següent.

A la vista d'aquest resultat concloem que l'ús d'histogrames no classifica bé les imatges en B/N. Provem ara un cas en què no tenim imatges en B/N, és a dir, considerant tan sols els formats:

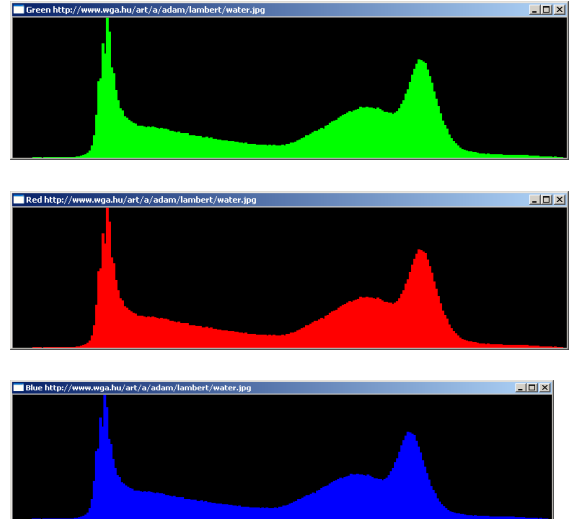
Atribut	Nombre de valors
Form	00001 ceramics
	00003 painting

Taula 12 Llista de forms

Imatge #6



Imatge #13



Il·lustració 28 Comparació dels histogrames de les imatges #6 i #13

**Execució número #2**

Considerarem el grup d'imatges d'obres d'art format per 4 elements de cada classe de la Taula 13:

Id classe	Id obra
1	0000001 0000002 0000003 0000004 0000005 0000006 0000007 0000008
3	0000009 0000010 0000011 0000012 0000013 0000014 0000015 0000016

Taula 13 Llista d'obres execució #2

El fitxer `url.txt` és

```
# Image url. Each row contains the id of the image and their url:
0000001 http://www.wqa.hu/art/a/sbaquesn/albarelli.jpg
0000002 http://www.wqa.hu/art/a/sbaquesn/floor1.jpg
0000003 http://www.wqa.hu/art/a/sbaquesn/floor2.jpg
0000004 http://www.wqa.hu/art/a/sbaquesn/theflood.jpg
0000005 http://www.wqa.hu/art/a/svelli/plate1.jpg
0000006 http://www.wqa.hu/art/a/svelli/plate.jpg
0000007 http://www.wqa.hu/art/d/durantin/plate.jpg
0000008 http://www.wqa.hu/preview/n/nicola/bowl.jpg
0000009 http://www.wqa.hu/art/a/sachen/allegory.jpg
0000010 http://www.wqa.hu/art/a/sachen/bacchus.jpg
0000011 http://www.wqa.hu/art/a/sachen/i_couple.jpg
0000012 http://www.wqa.hu/art/a/sbadia/michael.jpg
0000013 http://www.wqa.hu/art/a/sbbate/deerhunt.jpg
0000014 http://www.wqa.hu/art/a/sbbate/orpheus.jpg
0000015 http://www.wqa.hu/art/a/sbbate/proserpi.jpg
0000016 http://www.wqa.hu/art/a/sbbate/scipio.jpg
```

Il·lustració 29 Execució #1: fitxer url.txt



I el fitxer **labels.txt** conté:

```
# Image labels. Each row contains the id of the image and their labels:
# ImageID Author Technique Form Type School TimeFrame
0000001 0 0 1 0 0 0
0000002 0 0 1 0 0 0
0000003 0 0 1 0 0 0
0000004 0 0 1 0 0 0
0000005 0 0 1 0 0 0
0000006 0 0 1 0 0 0
0000007 0 0 1 0 0 0
0000008 0 0 1 0 0 0
0000009 0 0 3 0 0 0
0000010 0 0 3 0 0 0
0000011 0 0 3 0 0 0
0000012 0 0 3 0 0 0
0000013 0 0 3 0 0 0
0000014 0 0 3 0 0 0
0000015 0 0 3 0 0 0
0000016 0 0 3 0 0 0
```

II·lustració 30 Execució #2: fitxer labels.txt

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run2** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **4 folds**
- ❑ Cada *fold* amb **2** element de cada classe
- ❑ L'atribut "format" correspon al **#3**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

```
ProjecteMuseus.exe "../images_run2/" 4 2 3 0 1
```

Resultat: les imatges s'han baixat localment



II·lustració 31 Imatges execució #2

Resultat de la classificació: 93%

```

C:\WINDOWS\system32\cmd.exe
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run2/" 4 2 3 0 1
-----
Nombre d'elements trobats:16
Conjunt de dades dividit en 4 folds.
-----
Al Fold 1 hi tenim: 4, 6, 13, 14.
-----
Al Fold 2 hi tenim: 1, 5, 9, 16.
-----
Al Fold 3 hi tenim: 3, 7, 12, 15.
-----
Al Fold 4 hi tenim: 2, 8, 10, 11.
-----
Iteracio #1
Conjunt d'entrenament: 1, 2, 3, 5, 7, 8, 9, 10, 11, 12, 15, 16.
Conjunt de Test: 4, 6, 13, 14.
Resultat de la classificacio del conjunt de test:
Total Encerts: 4
Total Errors : 0
Bondat (%) : 100
-----
Iteracio #2
Conjunt d'entrenament: 2, 3, 4, 6, 7, 8, 10, 11, 12, 13, 14, 15.
Conjunt de Test: 1, 5, 9, 16.
Resultat de la classificacio del conjunt de test:
Total Encerts: 4
Total Errors : 0
Bondat (%) : 100
-----
Iteracio #3
Conjunt d'entrenament: 1, 2, 4, 5, 6, 8, 9, 10, 11, 13, 14, 16.
Conjunt de Test: 3, 7, 12, 15.
Resultat de la classificacio del conjunt de test:
Total Encerts: 4
Total Errors : 0
Bondat (%) : 100
-----
Iteracio #4
Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 9, 12, 13, 14, 15, 16.
Conjunt de Test: 2, 8, 10, 11.
Resultat de la classificacio del conjunt de test:
Total Encerts: 3
Total Errors : 1
Bondat (%) : 75
-----
El promig dels 4 folds es: 93 %.
-----
Prem una tecla per continuar...

```

II-Ilustració 32 Log execució #2 amb K=1

L'únic element que s'ha classificat malament ha estat a l'ultima iteració. Si tornem a executar el procés en mode *debug*, notem que l'error ha estat a la classificació de la imatge #8:

```

-----
Obra:8
Obra mes semblant:16
Classe Real:1
Classe Calculada:3
-----

```

Si en lloc de cercar amb el primer veí 1NN cerquem els 3 veïns més propers, la crida seria

```
ProjecteMuseus.exe "../images_run2/" 4 2 3 0 3
```

Obtenim el resultat següent:

```
C:\WINDOWS\system32\cmd.exe
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run2/" 4 2 3 0 3
-----
Nombre d'elements trobats:16
Conjunt de dades dividit en 4 folds.
-----
Al Fold 1 hi tenim: 4, 6, 13, 14.
-----
Al Fold 2 hi tenim: 1, 5, 9, 16.
-----
Al Fold 3 hi tenim: 3, 7, 12, 15.
-----
Al Fold 4 hi tenim: 2, 8, 10, 11.
-----
Iteracio #1
-----
Conjunt d'entrenament: 1, 2, 3, 5, 7, 8, 9, 10, 11, 12, 15, 16.
Conjunt de Test: 4, 6, 13, 14.
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 3
Total Errors : 1
Bondat (<%) : 75
-----
Iteracio #2
-----
Conjunt d'entrenament: 2, 3, 4, 6, 7, 8, 10, 11, 12, 13, 14, 15.
Conjunt de Test: 1, 5, 9, 16.
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 3
Total Errors : 1
Bondat (<%) : 75
-----
Iteracio #3
-----
Conjunt d'entrenament: 1, 2, 4, 5, 6, 8, 9, 10, 11, 13, 14, 16.
Conjunt de Test: 3, 7, 12, 15.
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 3
Total Errors : 1
Bondat (<%) : 75
-----
Iteracio #4
-----
Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 9, 12, 13, 14, 15, 16.
Conjunt de Test: 2, 8, 10, 11.
-----
Resultat de la classificacio del conjunt de test:
Total Encerts: 2
Total Errors : 2
Bondat (<%) : 50
-----
El promig dels 4 folds es: 68 %.
-----
Prem una tecla per continuar...
```

Il·lustració 33 Log execució #2 amb K=3

Així doncs, en augmentar K el resultat ha empitjorat, però encara es troba per sobre del llindar del 50%.

## Conclusions

A la vista dels resultats, sembla haver-hi una certa correlació entre els histogrames de color d'obres d'art del mateix format, però solament es pot aplicar a imatges d'obres d'art en color.

### Efecte del nombre de veïns a l'algorisme KNN de classificació

Hem vist que per  $K=1$  obtenim millors resultats que per  $K=3$ .

### Efecte del tipus de distància

A l'apartat 4.4 parlàvem de com OpenCV posa a la nostra disposició 4 mètriques diferents per avaluar la distància entre histogrames. Els resultats anterior s'han obtingut amb el tipus de distància CV\_COMP\_CHISQR.

La precisió que s'obté per cada tipus de mètrica és:

- ❑ CV\_COMP\_CORREL → 53%
- ❑ CV\_COMP\_CHISQR → 93%
- ❑ CV\_COMP\_INTERSECT → 50%
- ❑ CV\_COMP\_BHATTACHARYYA → 81%

Queda clar que el mètode de CV\_COMP\_CHISQR és el més eficient per comparar histogrames d'imatges d'obres d'art.

Com que hem vist que som capaços de classificar correctament el format de les obres d'art, ara treballarem amb obres d'art d'un format determinat. Als apartats següents analitzarem si podem distingir l'autor d'un format en concret (00003:painting), treballarem amb imatges de pintures.

### 6.3. Aplicació: Classificació per l'atribut "tipus"

#### Execució número #3

Considerarem el grup d'imatges de pintures format per 25 elements de cada classe:

Atribut	Nombre de valors
<b>Type</b>	00008 still-life
	00003 landscape
	00004 mythological
	00007 religious

Taula 14 Llista de classes de la execució #3

Id classe	Id obra
8	0000001 ... 0000025
3	0000026 ... 0000050
4	0000051 ... 0000075
7	0000076 ... 0000100

Taula 15 Llista d'imatges de la execució #3

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run3** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **5 folds**
- ❑ Cada *fold* amb **5** element de cada classe
- ❑ L'atribut "tipus" correspon al **#4**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

```
ProjecteMuseus.exe "../images_run3/" 5 5 4 0 1
```

## **Resultat**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run3/" 5 5 4 0 1
```

```
-----
Nombre d'elements trobats:100
-----
```

```
Conjunt de dades dividit en 5 folds.
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 24, 30, 47, 48, 49, 50, 51, 53, 54, 64, 72, 80, 83, 85, 89, 90,
```

```
-----
Al Fold 2 hi tenim: 1, 13, 15, 16, 20, 33, 38, 39, 45, 46, 55, 56, 63, 65, 66, 79, 81, 82, 87, 91,
```

```
-----
Al Fold 3 hi tenim: 2, 9, 14, 18, 19, 27, 28, 34, 42, 44, 70, 71, 73, 74, 75, 77, 78, 84, 88, 93,
```

```
-----
Al Fold 4 hi tenim: 7, 8, 22, 23, 25, 32, 35, 36, 40, 41, 57, 58, 60, 67, 69, 76, 94, 95, 98, 99,
```

```
-----
Al Fold 5 hi tenim: 3, 5, 6, 10, 21, 26, 29, 31, 37, 43, 52, 59, 61, 62, 68, 86, 92, 96, 97, 100,
```

```
-----
Iteracio #1
-----
```

```
Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2
```

```
1, 22, 23, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 4
```

```
3, 44, 45, 46, 52, 55, 56, 57, 58, 59, 60, 61, 62, 63, 65, 66, 67, 68, 69, 70, 7
```

```
1, 73, 74, 75, 76, 77, 78, 79, 81, 82, 84, 86, 87, 88, 91, 92, 93, 94, 95, 96, 9
```

```
7, 98, 99, 100,
```

```
Conjunt de test: 4, 11, 12, 17, 24, 30, 47, 48, 49, 50, 51, 53, 54, 64, 72, 80,83, 85, 89, 90,
```

```
-----
Resultat de la classificacio del conjunt de test:
```

```
Total Encerts: 13
```

Total Errors : 7

Bondat (%) : 65

-----  
Iteracio #2  
-----

Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 21, 2  
2, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 40, 41, 42, 43, 44, 4  
7, 48, 49, 50, 51, 52, 53, 54, 57, 58, 59, 60, 61, 62, 64, 67, 68, 69, 70, 71, 7  
2, 73, 74, 75, 76, 77, 78, 80, 83, 84, 85, 86, 88, 89, 90, 92, 93, 94, 95, 96, 9  
7, 98, 99, 100,

Conjunt de test: 1, 13, 15, 16, 20, 33, 38, 39, 45, 46, 55, 56, 63, 65, 66, 79,  
81, 82, 87, 91,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 8

Total Errors : 12

Bondat (%) : 40

-----  
Iteracio #3  
-----

Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 20, 21,  
22, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40, 41, 43, 45, 46,  
47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66,  
67, 68, 69, 72, 76, 79, 80, 81, 82, 83, 85, 86, 87, 89, 90, 91, 92, 94, 95, 96,  
97, 98, 99, 100,

Conjunt de test: 2, 9, 14, 18, 19, 27, 28, 34, 42, 44, 70, 71, 73, 74, 75, 77, 7  
8, 84, 88, 93,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 11

Total Errors : 9

Bondat (%) : 55

-----  
Iteracio #4  
-----

Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,  
19, 20, 21, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 42, 43, 44, 45, 46,  
47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 59, 61, 62, 63, 64, 65, 66, 68, 70, 71,  
72, 73, 74, 75, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92,  
93, 96, 97, 100,

Conjunt de test: 7, 8, 22, 23, 25, 32, 35, 36, 40, 41, 57, 58, 60, 67, 69, 76, 94,  
95, 98, 99,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 9

Total Errors : 11

Bondat (%) : 45

-----  
Iteracio #5  
-----

Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,  
22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40, 41, 42, 44, 45, 46,  
47, 48, 49, 50, 51, 53, 54, 55, 56, 57, 58, 60, 63, 64, 65, 66, 67, 69, 70, 71,  
72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 87, 88, 89, 90, 91, 93,  
94, 95, 98, 99,

Conjunt de test: 3, 5, 6, 10, 21, 26, 29, 31, 37, 43, 52, 59, 61, 62, 68, 86, 92,  
, 96, 97, 100,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 6

Total Errors : 14

Bondat (%) : 30

-----  
El promig dels 5 folds és: 47 %



Prem una tecla per continuar...






### Conclusions

Tenim una precisió de gairebé el **50%**, que és el doble de la probabilitat d'encert que tindriem si féssim la classificació aleatòriament que és del 25% (tenim 4 possibilitats igualment probables).

## 6.4. *Aplicació: Classificació per l'atribut "autor"*

### Execució número #4

Considerarem el grup d'imatges de pintures format per 20 elements de 5 classes dels autors següents:

00001 GAINSBOROUGH, Thomas	00002 GRÜNEWALD, Matthias	00003 GRECO, El
		
00004 VELÁZQUEZ, Diego	00005 Sandro BOTTICELLI	
		

Taula 16 Llista de classes de la execució #4

Notem que, a nivell de color, les obres de Boticelli són més diferents a la resta

Id classe	Id obra
1	0000001 ... 0000020
2	0000021 ... 0000040
3	0000041 ... 0000060
4	0000061 ... 0000080
5	0000081 ... 0000100

**Taula 17 Llista d'imatges de la execució #4**

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run4** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **5 folds**
- ❑ Cada *fold* amb **4** element de cada classe
- ❑ L'atribut "autor" correspon al **#1**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

```
ProjecteMuseus.exe "../images_run4/" 5 4 1 0 1
```

### **Resultat**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run4/" 5 4 1 0 5
```

```
-----
Nombre d'elements trobats:100
-----
```

```
Conjunt de dades dividit en 5 folds.
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 74, 77, 83, 86, 88, 92,
```

-----  
Al Fold 2 hi tenim: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 72, 73, 82, 84, 85, 90,  
-----

Al Fold 3 hi tenim: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,  
-----

Al Fold 4 hi tenim: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 71, 79, 95, 96, 99, 100,  
-----

Al Fold 5 hi tenim: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 75, 89, 93, 97, 98,  
-----

Iteracio #1  
-----

Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2  
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38, 41, 42, 43, 45, 4  
6, 47, 48, 51, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 65, 66, 67, 69, 70, 7  
1, 72, 73, 75, 76, 78, 79, 80, 81, 82, 84, 85, 87, 89, 90, 91, 93, 94, 95, 96, 9  
7, 98, 99, 100,

Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 74, 77,83, 86, 88, 92,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 4

Total Errors : 16

Bondat (%) : 20  
-----

Iteracio #2  
-----

Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 20, 2  
1, 22, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 39, 40, 41, 42, 44, 45, 4  
6, 47, 49, 50, 51, 52, 55, 56, 57, 58, 59, 60, 61, 63, 64, 65, 66, 67, 68, 69, 7  
1, 74, 75, 76, 77, 78, 79, 80, 81, 83, 86, 87, 88, 89, 91, 92, 93, 94, 95, 96, 9  
7, 98, 99, 100,

Conjunt de test: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 72, 73,82, 84, 85, 90,  
-----

Resultat de la classificació del conjunt de test:

Total Encerts: 4

Total Errors : 16

Bondat (%) : 20

-----  
Iteració #3  
-----

Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 20,  
21, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40, 42, 43, 44, 46,  
47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 61, 62, 63, 64, 65, 66, 67, 68,  
70, 71, 72, 73, 74, 75, 77, 79, 82, 83, 84, 85, 86, 88, 89, 90, 92, 93, 95, 96,  
97, 98, 99, 100,

Conjunt de test: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,  
-----

Resultat de la classificació del conjunt de test:

Total Encerts: 5

Total Errors : 15

Bondat (%) : 25

-----  
Iteració #4  
-----

Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,  
21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40, 41, 43, 44, 45,  
46, 48, 49, 50, 51, 52, 53, 54, 57, 58, 59, 60, 61, 62, 64, 65, 67, 68, 69, 70,  
72, 73, 74, 75, 76, 77, 78, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92,  
93, 94, 97, 98,

Conjunt de test: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 71, 79, 95, 96, 99, 100,  
-----

Resultat de la classificació del conjunt de test:

Total Encerts: 6

Total Errors : 14

Bondat (%) : 30

```
-----  
Iteracio #5  
-----
```

```
Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,  
21, 22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40, 41, 42, 43, 44,  
45, 47, 48, 49, 50, 52, 53, 54, 55, 56, 59, 60, 62, 63, 64, 66, 68, 69, 70, 71,  
72, 73, 74, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 90, 91, 92, 94,  
95, 96, 99, 100,  
Conjunt de test: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 75, 89, 93, 97, 98,  
-----
```

```
Resultat de la classificacio del conjunt de test:
```

```
Total Encerts: 6
```

```
Total Errors : 14
```

```
Bondat (%) : 30
```

```
-----  
El promig dels 5 folds és: 25 %.  
-----
```

```
Prem una tecla per continuar...
```


## **Conclusions**

Tenim una precisió d'un 25%, que millora molt poc la probabilitat d'encert que tindríem si féssim la classificació aleatòriament (que és del 20% perquè tenim 5 possibilitats igualment probables).

Notem que aquest tipus d'autors tenen unes pintures molt semblant entre elles. Repetim l'anàlisi però considerant ara tan sols les obres d'en Boticelli i d'en Velázquez, que a priori semblen les menys semblants entre elles.

**Execució número #5**

Considerarem el subconjunt d'imatges de pintures de l'execució anterior format per 20 elements de les classes:

00004 VELÁZQUEZ, Diego	00005 Sandro BOTTICELLI
	

**Taula 18 Llista de classes de la execució #5**

Id classe	Id obra
4	0000001 ... 0000020
3	0000021 ... 0000040

**Taula 19 Llista d'imatges de la execució #5**

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run5** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **5 folds**
- ❑ Cada *fold* amb **4** element de cada classe
- ❑ L'atribut "autor" correspon al **#1**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

`ProjecteMuseus.exe "../images_run5/" 5 4 1 0 1`

## **Resultat**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run5/" 5 4 1 0 1
```

```
-----
Nombre d'elements trobats:40
-----
```

```
Conjunt de dades dividit en 5 folds.
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 21, 30, 39, 40,
-----
```

```
Al Fold 2 hi tenim: 1, 13, 15, 16, 23, 24, 33, 38,
-----
```

```
Al Fold 3 hi tenim: 2, 9, 14, 18, 22, 27, 28, 34,
-----
```

```
Al Fold 4 hi tenim: 7, 8, 19, 20, 25, 32, 35, 36,
-----
```

```
Al Fold 5 hi tenim: 3, 5, 6, 10, 26, 29, 31, 37,
-----
```

```
Iteracio #1
-----
```

```
Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38,
```

```
Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40,
-----
```

```
Resultat de la classificacio del conjunt de test:
```

```
Total Encerts: 5
```

```
Total Errors : 3
```

```
Bondat (%) : 62
```

-----  
Iteracio #2  
-----

Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 20, 2  
1, 22, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 39, 40,  
Conjunt de test: 1, 13, 15, 16, 23, 24, 33, 38,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 5

Total Errors : 3

**Bondat (%) : 62**  
-----

Iteracio #3  
-----

Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 20,  
21, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40,  
Conjunt de test: 2, 9, 14, 18, 22, 27, 28, 34,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 6

Total Errors : 2

**Bondat (%) : 75**  
-----

Iteracio #4  
-----

Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,  
21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40,  
Conjunt de test: 7, 8, 19, 20, 25, 32, 35, 36,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 6

Total Errors : 2



Bondat (%) : 75

-----

Iteracio #5

-----

Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,  
21, 22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40,

Conjunt de test: 3, 5, 6, 10, 26, 29, 31, 37,

-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 5

Total Errors : 3

Bondat (%) : 62

-----

El promig dels 5 folds és: 67 %.

-----

Prem una tecla per continuar...

### **Conclusions**

Tenim una precisió d'un 67%, que millora la probabilitat d'encert que tindriem si féssim la classificació aleatòriament (que és del 50% perquè tenim 2 possibilitats igualment probables).

Queda clar que com més diferents són els tipus d'obra d'art, més alta és la probabilitat d'encert.

**Execució número #6**

Repetim ara el test #5 però amb pintures encara més diferents:

00001 VELÁZQUEZ, Diego	00002 Dalí
	

**Taula 20** Llista de classes de la execució #6

Id classe	Id obra
1	0000001 ... 0000020
2	0000021 ... 0000040

**Taula 21** Llista d'imatges de la execució #6

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run6** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ 5 *fold*s
- ❑ Cada *fold* amb 4 element de cada classe
- ❑ L'atribut "autor" correspon al #1
- ❑ Fem K=3 pel càlcul dels veïns més propers

És a dir, la crida és

`ProjecteMuseus.exe "../images_run6/" 5 4 1 0 1`

**Resultat (amb K=3)**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run6/" 5 4 1 0 3
```

```
-----
Nombre d'elements trobats:40
-----
```

```
Conjunt de dades dividit en 5 folds.
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 21, 30, 39, 40,
```

```
-----
Al Fold 2 hi tenim: 1, 13, 15, 16, 23, 24, 33, 38,
```

```
-----
Al Fold 3 hi tenim: 2, 9, 14, 18, 22, 27, 28, 34,
```

```
-----
Al Fold 4 hi tenim: 7, 8, 19, 20, 25, 32, 35, 36,
```

```
-----
Al Fold 5 hi tenim: 3, 5, 6, 10, 26, 29, 31, 37,
```

```
-----
Iteracio #1
-----
```

```
Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38,
```

```
Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40,
```

```
-----
Resultat de la classificacio del conjunt de test:
```

```
Total Encerts: 8
```

```
Total Errors : 0
```

```
Bondat (%) : 100
```

Iteracio #2

-----  
Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 20, 21, 22, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 39, 40,  
Conjunt de test: 1, 13, 15, 16, 23, 24, 33, 38,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 6

Total Errors : 2

Bondat (%) : 75

-----  
Iteracio #3

-----  
Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 20, 21, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40,  
Conjunt de test: 2, 9, 14, 18, 22, 27, 28, 34,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 6

Total Errors : 2

Bondat (%) : 75

-----  
Iteracio #4

-----  
Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40,  
Conjunt de test: 7, 8, 19, 20, 25, 32, 35, 36,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 7

Total Errors : 1

Bondat (%) : 87

```

-----
Iteracio #5
-----

Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,
 21, 22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40,
Conjunt de test: 3, 5, 6, 10, 26, 29, 31, 37,
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 7

Total Errors : 1

Bondat (%) : 87
-----

El promig dels 5 folds es: 84 %.
-----

```

### **Comparació resultats amb K=1 i K=3**

Si amb K=3 el resultat és d'un 84%, el resultat amb K=1 és una mica pitjor: el promig de les 3 iteracions dóna un 79%. Per exemple, a la primera iteració, amb K=3 classifica correctament totes les pintures. Si mirem el log generat en mode debug tenim (en vermell mostrem els veïns més propers que no pertanyen al mateix autor de l'obra que estem classificant).

```

Iteracio #1
-----

Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38,
Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40,
Les obres més semblants a 4 són: 20, 27, 16,
Les obres més semblants a 11 són: 38, 10, 15,
Les obres més semblants a 12 són: 2, 1, 8,
Les obres més semblants a 17 són: 16, 20, 27,
Les obres més semblants a 21 són: 22, 32, 34,
Les obres més semblants a 30 són: 31, 32, 34,
Les obres més semblants a 39 són: 37, 28, 26,
Les obres més semblants a 40 són: 35, 14, 37,

```

Si fem el mateix per K=1 tenim:

Iteracio #1

-----  
 Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2  
 2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38,

Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40,

Les obres més semblants a 4 són: 20,

Les obres més semblants a 11 són: 38,

Les obres més semblants a 12 són: 2,

Les obres més semblants a 17 són: 16,

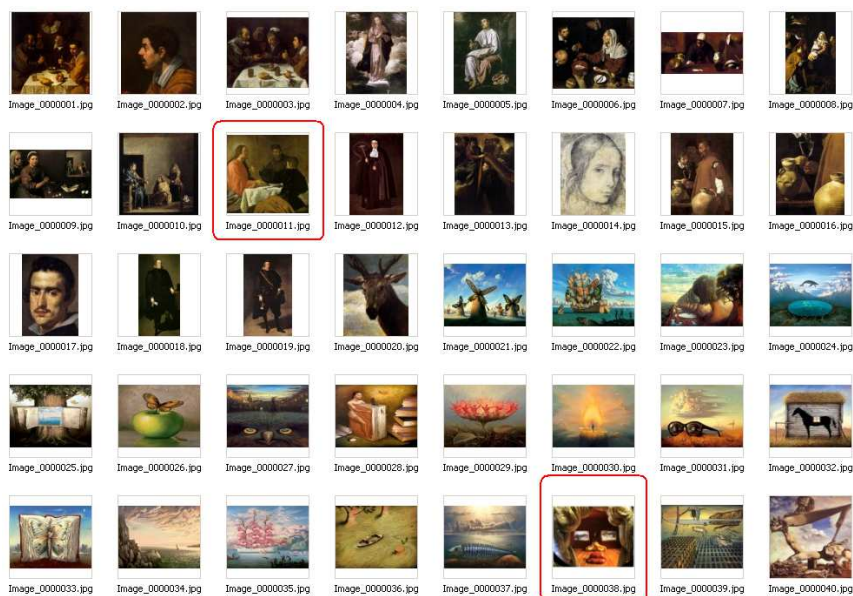
Les obres més semblants a 21 són: 22,

Les obres més semblants a 30 són: 31,

Les obres més semblants a 39 són: 37,

Les obres més semblants a 40 són: 35,

-----  
 Notem que, amb K=1, l'obra #11 està mal classificada, perquè el veí més proper, l'obra 38, no és del mateix autor. En el cas K=3 si que està ben classificada perquè encara que l'obra #38 es el veí més proper, els següents 2 veïns sí que són de l'autor correcte. A continuació mostrem les 40 obres que hem fet servir:

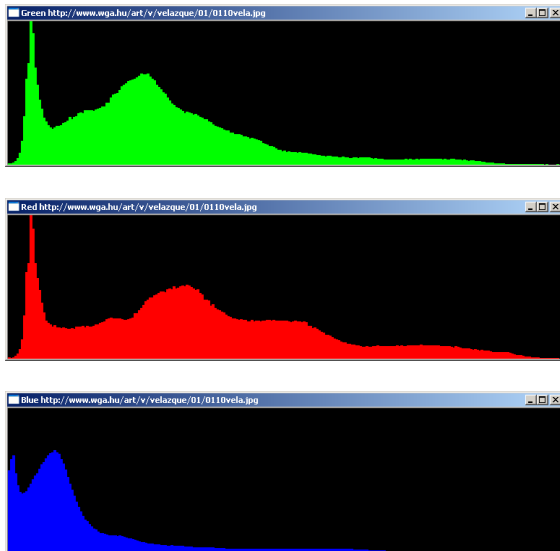


Il·lustració 34 Obres d'art de la execució 35


Les primeres 20 obres són de Velázquez i les 20 següents són de Dalí. Notem que l'obra #11 de Velázquez és, pel que fa al tema de la distribució de color, la més semblant a les obres de Dalí, i que l'obra #38 de Dalí, es l'obra més semblant a les de Velázquez.

A continuació mostrem els histogrammes d'aquestes 2 imatges, on s'observa una certa similitud.

Imatge #11



Imatge #38



Il·lustració 35 Comparació Histogrames de les imatges #38 i #11

### Conclusions

Amb  $K=3$  tenim una precisió d'un 84%, que millora en molt la probabilitat d'encert que tindriem si féssim la classificació aleatòriament (que és del 50% perquè tenim 2 possibilitats igualment probables). També millora el resultat de l'execució anterior. Això és a causa de l'ús del color que fan aquest dos autors que és molt diferent.

S'ha repetit el càlcul amb  $K=1$  i la probabilitat d'encert ha empitjorat lleugerament (79%).

## 6.5. Aplicació: Classificació per l'atribut "escola"

### Execució número #7

Considerarem el grup d'imatges de pintures format per 20 elements de 5 escoles diferents

Escola	Nombre de valors
00001	Austrian
00002	Catalan
00003	German
00004	Italian
00005	Spanish

**Taula 22** Llista de classes de la execució #7

Id classe	Id obra
00001	0000001 ... 0000020
00002	0000021 ... 0000040
00003	0000041 ... 0000060
00004	0000061 ... 0000080
00005	0000081 ... 0000100

**Taula 23** Llista d'imatges de la execució #7

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run7** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ 5 folds
- ❑ Cada fold amb 4 element de cada classe
- ❑ L'atribut "escola" correspon al #5
- ❑ Fem K=1 pel càlcul dels veïns més propers



És a dir, la crida és

```
ProjecteMuseus.exe "../images_run7/" 5 4 5 0 3
```

### **Resultat**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run7/" 5 4 5 0 3
```

```
-----
```

```
Nombre d'elements trobats:100
```

```
-----
```

```
Conjunt de dades dividit en 5 folds.
```

```
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 73, 77, 83, 86, 88, 92,
```

```
-----
```

```
Al Fold 2 hi tenim: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 71, 72, 82, 84, 85, 90,
```

```
-----
```

```
Al Fold 3 hi tenim: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,
```

```
-----
```

```
Al Fold 4 hi tenim: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 75, 79, 95, 96, 99, 100,
```

```
-----
```

```
Al Fold 5 hi tenim: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 74, 89, 93, 97, 98,
```

```
-----
```

```
Iteracio #1
```

```
-----
```

```
Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2
```

```
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38, 41, 42, 43, 45, 4
```

```
6, 47, 48, 51, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 65, 66, 67, 69, 70, 7
```

```
5, 71, 72, 74, 76, 78, 79, 80, 81, 82, 84, 85, 87, 89, 90, 91, 93, 94, 95, 96, 9
```

```
7, 98, 99, 100,
```

```
Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 73, 77,83, 86, 88, 92,
```

-----  
Resultat de la classificació del conjunt de test:

Total Encerts: 5

Total Errors : 15

Bondat (%) : 25

-----  
Iteració #2

-----  
Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 20, 21, 22, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 39, 40, 41, 42, 44, 45, 46, 47, 49, 50, 51, 52, 55, 56, 57, 58, 59, 60, 61, 63, 64, 65, 66, 67, 68, 69, 70, 73, 74, 76, 77, 78, 79, 80, 81, 83, 86, 87, 88, 89, 91, 92, 93, 94, 95, 96, 97, 98, 99, 100,

Conjunt de test: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 71, 72, 82, 84, 85, 90,

-----  
Resultat de la classificació del conjunt de test:

Total Encerts: 4

Total Errors : 16

Bondat (%) : 20

-----  
Iteració #3

-----  
Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 20, 21, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40, 42, 43, 44, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 61, 62, 63, 64, 65, 66, 67, 68, 70, 75, 71, 72, 73, 74, 77, 79, 82, 83, 84, 85, 86, 88, 89, 90, 92, 93, 95, 96, 97, 98, 99, 100,

Conjunt de test: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,

-----  
Resultat de la classificació del conjunt de test:

Total Encerts: 6

Total Errors : 14

Bondat (%) : 30

-----  
Iteracio #4  
-----

Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,  
21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40, 41, 43, 44, 45,  
46, 48, 49, 50, 51, 52, 53, 54, 57, 58, 59, 60, 61, 62, 64, 65, 67, 68, 69, 70,  
71, 72, 73, 74, 76, 77, 78, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92,  
93, 94, 97, 98,

Conjunt de test: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 75, 79, 95, 96, 99, 100,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 3

Total Errors : 17

Bondat (%) : 15

-----  
Iteracio #5  
-----

Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,  
21, 22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40, 41, 42, 43, 44,  
45, 47, 48, 49, 50, 52, 53, 54, 55, 56, 59, 60, 62, 63, 64, 66, 68, 69, 70, 75,  
71, 72, 73, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 90, 91, 92, 94,  
95, 96, 99, 100,

Conjunt de test: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 74, 89, 93, 97, 98,  
-----

Resultat de la classificacio del conjunt de test:

Total Encerts: 5

Total Errors : 15

Bondat (%) : 25

-----  
El promig dels 5 folds es: 23 %  
-----

Prem una tecla per continuar...

### Conclusions

Tenim una precisió molt baixa, d'un 23%, que és similar a la probabilitat d'encert que tindríem si féssim la classificació aleatòriament (20%). Sembla, doncs, que els histogrames de pintures de la mateixa escola són massa diferent entre ells per poder inferir alguna característica comuna que els pugui diferenciar d'altres escoles.

Si repetim el test amb K=1 obtenim una precisió similar d'un 24%.

## 6.6. *Aplicació: Classificació per l'atribut "període"*

### Execució número #8

Considerarem el grup d'imatges de pintures format per 20 elements de 5 períodes diferents

Període	Nombre de valors
00001	1051-1100
00002	1251-1300
00003	1451-1500
00004	1601-1650
00005	1801-1850

**Taula 24** Llista de classes de la execució #8

Id classe	Id obra
00001	0000001 ... 0000020
00002	0000021 ... 0000040
00003	0000041 ... 0000060
00004	0000061 ... 0000080
00005	0000081 ... 0000100

**Taula 25** Llista d'imatges de la execució #8

Assumim que el conjunt de dades i fitxers es troba en una carpeta **images\_run8** dintre del directori arrel del projecte.

Executem la classificació amb els paràmetres corresponents a

- ❑ **5 folds**
- ❑ Cada *fold* amb **4** element de cada classe
- ❑ L'atribut "període" correspon al **#6**
- ❑ Fem **K=1** pel càlcul dels veïns més propers

És a dir, la crida és

```
ProjecteMuseus.exe "../images_run8/" 5 4 6 0 3
```

### **Resultat**

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus>cd Release
```

```
C:\Documents and Settings\Luis\My Documents\Visual Studio 2010\Projects\Projecte
Museus\Release>ProjecteMuseus.exe "../images_run8/" 5 4 6 0 3
```

```
-----
Nombre d'elements trobats:100
-----
```

```
Conjunt de dades dividit en 5 folds.
-----
```

```
Al Fold 1 hi tenim: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 74, 77, 83, 86, 88, 92,
-----
```

```
Al Fold 2 hi tenim: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 72, 73, 82, 84, 85, 90,
-----
```

```
Al Fold 3 hi tenim: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,
-----
```

```
Al Fold 4 hi tenim: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 71, 79, 95, 96, 99, 100,
-----
```

Al Fold 5 hi tenim: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 75, 89, 93, 97, 98,

-----  
Iteracio #1  
-----

Conjunt d'entrenament: 1, 2, 3, 5, 6, 7, 8, 9, 10, 13, 14, 15, 16, 18, 19, 20, 2  
2, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 36, 37, 38, 41, 42, 43, 45, 4  
6, 47, 48, 51, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 65, 66, 67, 69, 70, 7  
1, 72, 73, 75, 76, 78, 79, 80, 81, 82, 84, 85, 87, 89, 90, 91, 93, 94, 95, 96, 9  
7, 98, 99, 100,

Conjunt de test: 4, 11, 12, 17, 21, 30, 39, 40, 44, 49, 50, 52, 64, 68, 74, 77,83, 86, 88, 92,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 14

Total Errors : 6

Bondat (%) : 70

-----  
Iteracio #2  
-----

Conjunt d'entrenament: 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 14, 17, 18, 19, 20, 2  
1, 22, 25, 26, 27, 28, 29, 30, 31, 32, 34, 35, 36, 37, 39, 40, 41, 42, 44, 45, 4  
6, 47, 49, 50, 51, 52, 55, 56, 57, 58, 59, 60, 61, 63, 64, 65, 66, 67, 68, 69, 7  
1, 74, 75, 76, 77, 78, 79, 80, 81, 83, 86, 87, 88, 89, 91, 92, 93, 94, 95, 96, 9  
7, 98, 99, 100,

Conjunt de test: 1, 13, 15, 16, 23, 24, 33, 38, 43, 48, 53, 54, 62, 70, 72, 73,82, 84, 85, 90,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 8

Total Errors : 12

Bondat (%) : 40

-----  
Iteracio #3  
-----

Conjunt d'entrenament: 1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 20,  
21, 23, 24, 25, 26, 29, 30, 31, 32, 33, 35, 36, 37, 38, 39, 40, 42, 43, 44, 46,  
47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 61, 62, 63, 64, 65, 66, 67, 68,  
70, 71, 72, 73, 74, 75, 77, 79, 82, 83, 84, 85, 86, 88, 89, 90, 92, 93, 95, 96,  
97, 98, 99, 100,  
Conjunt de test: 2, 9, 14, 18, 22, 27, 28, 34, 41, 45, 59, 60, 69, 76, 78, 80, 81, 87, 91, 94,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 11

Total Errors : 9

Bondat (%) : 55

-----  
Iteracio #4

-----  
Conjunt d'entrenament: 1, 2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18,  
21, 22, 23, 24, 26, 27, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40, 41, 43, 44, 45,  
46, 48, 49, 50, 51, 52, 53, 54, 57, 58, 59, 60, 61, 62, 64, 65, 67, 68, 69, 70,  
72, 73, 74, 75, 76, 77, 78, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92,  
93, 94, 97, 98,  
Conjunt de test: 7, 8, 19, 20, 25, 32, 35, 36, 42, 47, 55, 56, 63, 66, 71, 79, 95, 96, 99, 100,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 10

Total Errors : 10

Bondat (%) : 50

-----  
Iteracio #5

-----  
Conjunt d'entrenament: 1, 2, 4, 7, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20,  
21, 22, 23, 24, 25, 27, 28, 30, 32, 33, 34, 35, 36, 38, 39, 40, 41, 42, 43, 44,

45, 47, 48, 49, 50, 52, 53, 54, 55, 56, 59, 60, 62, 63, 64, 66, 68, 69, 70, 71,  
72, 73, 74, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 90, 91, 92, 94,  
95, 96, 99, 100,

Conjunt de test: 3, 5, 6, 10, 26, 29, 31, 37, 46, 51, 57, 58, 61, 65, 67, 75, 89, 93, 97, 98,

-----  
Resultat de la classificacio del conjunt de test:

Total Encerts: 12

Total Errors : 8

Bondat (%) : 60

-----  
El promig dels 5 folds és: 55 %  
-----

Prem una tecla per continuar...

### **Conclusions**

Tenim una precisió d'un **55%**, que és més del doble de la probabilitat d'encert que tindríem si féssim la classificació aleatòriament (que és del 20% perquè tenim 5 possibilitats igualment probables). És un resultat similar a l'obtingut a l'apartat 6.3 on analitzàvem la classificació per tipus.



## 7. Conclusions y treballs futurs

En aquest capítol es resumeixen les conclusions obtingudes en aplicar el software generat a l'anàlisi de la viabilitat de la classificació d'obres d'art mitjançant l'anàlisi dels histogrames, i proposem possibles extensions del treball.

### 7.1. Conclusions

Hem vist que l'ús d'histogrames no classifica bé les imatges en B/N.

#### Classificació per format

En el procés de classificació d'obres segons el seu format, els resultats obtinguts suggereixen una bona correlació entre els histogrames de color d'obres d'art del mateix format (però solament es pot aplicar a imatges d'obres d'art en color).

Com que hem vist que som capaços de classificar correctament el format de les obres d'art, les anàlisis posteriors de classificació segons altres atributs, s'han fet en un format concret: la pintura.

#### Efecte del nombre de veïns a l'algorisme KNN de classificació

No queda clar l'efecte del nombre de veïns a l'algorisme KNN de classificació. De vegades s'obtenen millors resultats per  $K=1$  que per  $K=3$  i de vegades és al revés.

Per mostres més grans el valor  $K=3$  dona millor resultat.

#### Efecte del tipus de distància

A l'apartat 4.4 parlàvem de com OpenCV posa a la nostra disposició 4 mètriques diferents per avaluar la distància entre histogrames. Hem vist que el mètode de CV\_COMP\_CHISQR és el més eficient per comparar histogrames d'imatges d'obres d'art.

#### Classificació per autor

Queda clar que com més diferents són les pintures d'un autor de les d'un altre, més alta és la probabilitat de classificació correcta.

Per exemple, podem distingir una obra de Velázquez d'una de Dalí amb una precisió d'un 87%. D'altra banda, si la volem distingir d'una de Boticelli aquesta probabilitat d'encert baixa a un 67%. No obstant això, la probabilitat d'encert es manté per sobre del 50 % (tria aleatòria).

### **Classificació per escola**

Tenim una precisió molt baixa, similar a la probabilitat d'encert que tindriem si féssim la classificació aleatòriament. Sembla doncs, que els histogrames de pintures de la mateixa escola són massa diferents entre ells per poder inferir alguna característica comuna que els pugui diferenciar d'altres escoles.

### **Classificació per període i per tipus**

S'ha trobat una precisió de més del doble de la probabilitat d'encert que tindriem si féssim una tria aleatòria. Llavors sembla existir una certa correlació entre les obres d'art de les mateix període i/o tipus, el que fa que l'anàlisi d'histogrames sigui una característica rellevant per a la classificació d'obres d'art. Rellevant no vol dir que suficient: cal afegir d'altres característiques per arribar a precisions del voltant del 90%.

## **7.2. Propostes per continuar**

Ampliar el programari per incloure altres característiques de les imatges de les obres d'art. Tècnicament caldria modificar la classe **Obra** per incloure el càlcul de la característica que es vol considerar. També caldria redefinir el mètode **distància()** per incloure la comparació d'aquesta característica.

## 8. Bibliografia

Les imatges analitzades en aquest treball s'han extret majoritàriament de la web <http://www.wga.hu/art/> (veure apèndix 9.1).

A més he consultat i/o fet servir les pàgines web següents:

- ❑ <http://images.google.es/>
- ❑ [http://ca.wikipedia.org/wiki/Visi%C3%B3\\_artificial](http://ca.wikipedia.org/wiki/Visi%C3%B3_artificial)
- ❑ [http://in3.uoc.edu/opencms\\_portalin3/opencms/ca/recerca/list/sunai\\_scene\\_understanding\\_and\\_artificial\\_intelligence\\_lab](http://in3.uoc.edu/opencms_portalin3/opencms/ca/recerca/list/sunai_scene_understanding_and_artificial_intelligence_lab)
- ❑ <http://www.sphoto.com/techinfo/histograms/histograms2.htm>
- ❑ <http://opencv.willowgarage.com>
- ❑ <http://robotzeitgeist.com/tag/object-recognition>
- ❑ [http://upcommons.upc.edu/pfc/bitstream/2099.1/9782/1/PFC\\_RogerGimeno.pdf](http://upcommons.upc.edu/pfc/bitstream/2099.1/9782/1/PFC_RogerGimeno.pdf)
- ❑ <http://www.cis.pku.edu.cn/faculty/vision/wangliwei/pdf/IMED.pdf>
- ❑ <http://www.public.asu.edu/~ltang9/papers/ency-cross-validation.pdf>
- ❑ [http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=5675821](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=5675821)

Libres consultats:

- ❑ Digital Image Processing (3rd Edition)  
DE Rafael C. Gonzalez y Richard E. Woods

## 9. Apèndix

### 9.1. Origen de les imatges de les obres d'art

La major part de les imatges de les obres d'art utilitzades en aquest treball han estat obtingudes de la web

<http://www.wga.hu/art/>

Aquesta web habilita un motor de cerca d'imatges d'obres d'art:

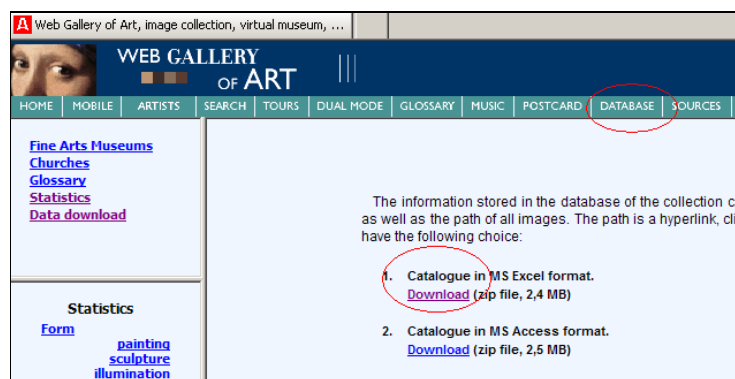
The screenshot shows the search interface of the Web Gallery of Art website. The 'SEARCH' menu item is circled in red. The search form includes the following fields and options:

- Author:  Any
- Title:
- Text:
- Time-line:  any
- Form:  any
- Location:  Any
- School:
- Type:

Buttons: Search! Clear

II-lustració 36 Cercador de la web

També permet descarregar (opció download) un excel amb les url de les imatges i els seus atributs:



II-lustració 37 Opció de descàrrega d'imatges