



SCENE CLASSIFIER FOR REAL TIME ROAD DETECTION

Memòria del Projecte Fi de Carrera
d'Enginyeria en Informàtica
realitzat per Enric Gili Albareda
i dirigit per José Manuel Álvarez
Bellaterra, 1 de juny de 2009



El sotasignat, José Manuel Álvarez

Professor/a de l'Escola Tècnica Superior d'Enginyeria de la UAB,

CERTIFICA:

Que el treball a què correspon aquesta memòria ha estat realitzat sota la seva direcció per en

I per tal que consti firma la present.

Signat:

Bellaterra, 1 de Juny de 2009

Índex

1. Introducció	1
1.1 Presentació i explicació del projecte	1
1.2 Objectius del projecte	2
1.3 Planificació	3
1.4 Estudi de viabilitat	4
2. Estat de l'art	6
2.1 Classificació d'escenes amb carreteres	6
2.1.1 Escenes de boira	6
2.1.2 Escenes de pluja	7
2.1.3 Escenes urbanes i rurals	8
2.1.4 Escenes de dia i nit	8
3. Mètodes implementats	9
3.1 Algoritmes	10
3.1.1 Detecció de boira	10
3.1.2 Detecció de pluja	12
3.1.3 Classificació en zona rural i urbana	14
3.1.4 Classificació en imatge nocturna i diürna	16
3.1.5 Fitxer de sortida	19

3.2 Mètode d'entrenament	20
3.2.1 Support Vector Machine	20
3.3 Detecció de cantonades	21
3.3.1 Filtre de Prewitt i de ZeroCross	21
4. Experiments	22
4.1 Base de dades	22
4.2 Imatges rebutjades	29
4.3 Parametrització dels algoritmes	32
4.4 Resultats	33
4.4.5 Fitxer de resultats	35
4.5 Experiments parcials i alternatives descartades	37
5. Comparativa de resultats	40
6. Conclusió	42
6.1 Discussió de resultats	42
6.2 Conclusió general	42
6.3 Treball futur	43
6.4 Valoració personal	43
7. Referències	44

8. Apèndix	45
8.1 Base d'imatges usades per entrenament	45
8.2 Dedicació	46

1. Introducció

1.1 Presentació i explicació del projecte

La conducció i els automòbils han esdevingut una peça indispensable en la societat d'avui en dia. Depenem d'ells. És per això que s'han buscat millores a nivell de seguretat, eficiència i confort del conductor.

Unint les noves tecnologies i "l'atenció al conductor" s'ha anat treballant en sistemes d'avís al conductor usant la intel·ligència artificial.

Un dels avantatges dels sistemes basats en la Visió artificial respecte altres tècniques (GPS, LADAR) és la seva fàcil implementació i integració i el seu baix cost.

Una de les coses més importants de la comunitat Visió Artificial / sistemes d'assistència a la conducció és el de la detecció de carreteres.

Un dels objectius i finalitats més importants de la detecció de carreteres i escenaris de carreteres és el de la conducció autònoma, l'assistència a altres sistemes com la detecció de vianants.

Tot i així se'ns presenten una sèrie de problemes, per exemple el de la generalitat; és a dir, per obtenir un funcionament òptim dels sistemes d'assistència i detecció en la conducció necessitaríem un algoritme capaç de solucionar al màxim, i si es pogués tots, els problemes plantejats.

Actualment existeixen molts grups d'estudi enfocats en la visió artificial, detecció de canvis d'escena, prevenció de riscos mitjançant la intel·ligència artificial, etc.

És per això que en aquest projecte ens adrecem a la classificació dels possibles escenaris en la conducció i la seva manera de presentar-los i solventar-ne les situacions.

Posant com a element important la seguretat, es plantegen qüestions com: És possible detectar si plou molt? És possible avisar al conductor si el cotxe de davant està massa a prop nostre? És possible avisar al conductor amb la màxima rapidesa si se'ns presenta una situació de risc?

1.2 Objectius del projecte

Donada la problemàtica presentada, l'objectiu principal del projecte és el de classificar escenes de carretera en funció del contingut de les imatges per així poder fer un desglossament sobre quin tipus de situació tenim en el moment.

És important que fixem els paràmetres necessaris en funció de l'escenari en què ens trobem per tal de treure el màxim rendiment possible a cada un dels algoritmes.


La seva funcionalitat doncs, ha de ser la d'avís i suport davant els diferents escenaris de conducció. És a dir, el resultat final ha de contenir un algoritme o aplicació capaç de classificar les imatges d'entrada en diferents tipus amb la màxima eficiència espacial i temporal possible. L'algoritme haurà de classificar les imatges en diferents escenaris.

Els algoritmes hauran de ser parametrizables i fàcilment manejables per l'usuari.

L'eina utilitzada per aconseguir aquests objectius serà el MATLAB amb les toolboxes de visió i xarxes neuronals instal·lades.

1.3 Planificació

En la taula 1.1 es pot observar la planificació inicial prevista i final real de l'execució del projecte:



Taula 1.1

El desenvolupament del projecte s'ha desglossat en 4 parts importants:

- Anàlisi de requeriments: què volem que solucioni el projecte? De quines eines disposem? A on podem buscar informació? Finalment, quines propostes tenim? Quin d'elles creiem que és la opció més bona per solventar la qüestió? És en aquesta fase on s'han buscat les respostes a les anteriors preguntes. En la taula 1 anterior es pot veure que aquesta fase ha durat aproximadament des de finals d'octubre a mitjans de gener.
- Codificació: un cop hem recollit suficient informació passem a aquesta fase. Desenvolupament de les aplicacions. Aquí igualment s'analitzen diferents opcions de solucionar els problemes i es busca la més adequada i eficient. La durada de la codificació de cada classificador ha variat segons la dificultat del mateix o segons les modificacions i perfeccions després de veure'n l'eficiència. Aquesta fase ha durat, per a tots els classificadors, des de desembre fins abril.

- Proves i Test: comprovació dels resultats obtinguts tant a nivell general com algoritme per algoritme. Hem solucionat el problema? És eficient? Com ho podríem millorar? Aquesta fase va començar a l'abril i va finalitzar al maig.
- Documentació: pro i post-codificació. Documentació durant la codificació a nivell de procediments òptims i a nivell de memòria final d'exposició de resultats i mètodes. Aquesta fase s'ha anat desenvolupant al llarg de tot el projecte.

1.4 Estudi de viabilitat

La següent taula mostra l'estudi de viabilitat econòmica del projecte. S'han tingut en compte els honoraris del director del projecte i del desenvolupador, així com els instruments per a realitzar-lo: ordinador personal i càmera de fotografar per a obtenir la base de dades de les imatges:

DESCRIPCIÓ	HORES DE FEINA	COST/HORA (€)	COST TOTAL (€)
-------------------	-----------------------	----------------------	-----------------------

RECURSOS			
Direcció del projecte	50	15	750
Desenvolupament	500	7	3500
Totals			4250

HW/INSTRUMENT			
Ordinador			700
Càmera fotogràfica			200
Totals			900

TOTALS			5150
---------------	--	--	-------------

Taula 1.2 Desglossament de les hores dedicades al projecte i càlcul aproximat dels honoraris respectius

Desglossarem la memòria del projecte *Scene Classifier or real time road detection* en els següents punts.

En la secció 2 següent s'explicarà l'estat de l'art de la classificació mitjançant la visió artificial en imatges de carretera. En la secció 3 s'explicaran els mètodes implementats per la resolució del problema. En la secció 4 s'explicaran els experiments fets durant la fase de desenvolupament, així com la base de dades d'imatges usades i les imatges rebutjades per ser usades. En la secció 5 es farà una comparativa d'eficiència i resultats amb altres alternatives semblants. En la secció 6 s'exposaran les conclusions, valoracions personals i el treball futur. Finalment, a l'última part hi haurà els annexos.

2. Estat de l'art

2.1 Classificació d'escenes amb carreteres

L'objectiu principal de la Visió per Computador és el de fer entendre a una màquina una escena o les seves característiques.

El projecte en sí es centra en l'ús de la intel·ligència artificial pels cotxes i per les imatges "on-road", de tal manera que pugui classificar escenes.

Ara per ara, no hi ha cap projecte important que sigui capaç de fer totes les deteccions i classificacions a la vegada de manera eficient. Cada universitat, institució, empresa, etc. s'ha centrat en un camp en concret.

Treballs relacionats amb la distinció general, Fang, Chen i Fuh

[7], proposen detectar canvis bruscos de l'ambient mentre es condueix. S'usen sensors per detectar els canvis.

Proposen usar xarxes neuronals per dur a terme el seu algoritme.

El problema és que no és especialment eficient. Només funciona en casos regulars, és a dir, quan plou o neva no funciona adequadament. Només classifica bé si fa sol o no plou.

Moltes d'aquestes aplicacions estan o estaran destinades a la detecció i avís de riscos en la conducció.

S'han registrat diverses bases de dades d'imatges (per al públic també) que poden ser usades pels programadors per exemple. Una d'elles és la de la Columbia University, amb imatges fetes durant 5 mesos [4].

L'estat de l'art del projecte el separarem en 4 parts importants: detecció de la boira, detecció de la pluja, classificació en zones rurals i urbanes i classificació en imatges de dia i de nit.

2.1.1 Classificadors i detectors de boira

Hi ha moltes investigacions centrades amb la detecció de boira en la carretera i en algunes fins i tot, en la detecció de la distància fins la qual la visibilitat és prou bona.

Un dels treballs més importants; Nicolas Hautière, Jean-Philippe Tarel, Jean Lavenant, Didier Aubert [5] proposa calcular la “distància meteorològica de visibilitat”, és a dir, trobar la distància més gran a la que un objecte negre es pot distingir.

L’algoritme primer busca una regió de la imatge en que hi hagi línies que creuin la imatge (per exemple les línies de la carretera).

Segueixen una sèrie de passos: trobar discontinuïtats, buscar la regió, buscar píxels que s’agreguin a la regió,...

Aquest algoritme resulta eficient en casos molt concrets, les imatges han de tenir almenys un tros de cel i un d’asfalt i a part busca línies que es creuin en les escenes, cosa que no necessàriament pot ocórrer.

Hi ha una variant, Yi-Shu Zhai, Xiao-Ming Liu [6], molt semblant que usa mètodes similars.

Per a solucionar el problema que se’ns presenta, només ens cal detectar si hi ha boira, no necessitem a quina distància es troba. Per altra banda és millor fer un algoritme que no hagi de complir unes condicions massa concretes (tenir cel i asfalt a la imatge) i que sigui més genèric.

Pel que fa a la detecció de boira, està previst que s’introdueixin sistemes al cotxe com a avís al conductor en cas de condicions de boira extremes.

2.1.2 Classificadors i detectors de pluja

Pel que fa a la pluja, s’hi ha investigat molt en camps més variats. El seu ús en el camp de la televisió seria la detecció i eliminació dels efectes de la pluja (gotes, visibilitat i dinàmica) en les imatges.

Hi ha treballs que presenten, per exemple Hiroyuki Kurihata i Tomokazu Takahashi [3], un algoritme que és capaç de detectar la pluja (o com la pluja cau) des d’una càmera de vehicle interior mitjançant PCA i Eigendrops.

El mètode el separen en entrenament (imatges de pluja, PCA i Eigendrop), detecció (matching amb la plantilla) i judici (pluja o no pluja, segons tot l’ anterior).

És un algoritme que detecta la pluja basant-se en 3 fets només: dibuixos de la pluja (línies), color darrera les gotes i reflexió de la llum.

Aquest algoritme requereix que existeixin una sèrie d’elements per tal de detectar les gotes, necessiten punts de llum a la imatge, o aconseguir d’alguna manera (ja sigui per processat d’imatges, enfocament,...).

Altres investigacions es centren en la detecció i eliminació, com per exemple el de Kshitiz Garg and Shree K. Nayar [2], de gotes de pluja en les escenes. La utilitat d'aquests algorismes es centra sobretot en la televisió (eliminació de les gotes en escenes de sèries de televisió).

Centrat en escenes de carretera no és especialment eficient.

És important aconseguir un algorisme que classifiqui, i entreni, el millor possible les gotes i les escenes de pluja intentant que no hi hagi restriccions d'ús massa grans.

2.1.3 Classificadors en urbà i rural

No s'ha investigat massa en aquest camp, però hi ha grup d'investigació, Thulasiraman i Prakash [1], que usa xarxes neuronals LVQ i espais de colors HSV per entrenar.

El seu objectiu és trobar un conjunt robust de característiques per classificar semànticament les imatges.

La metodologia és usant Dimensions Fractals (representar informació del patró de textures), característiques dels color (HSV), descriptors de Fourier i generació de característiques i amb aprenentatge del vector/xarxa LVQ.

Demostren tenir una fiabilitat elevada a preu d'usar massa paràmetres, descriptors i complexitat del sistema.

Tenen falsos positius produïts per cases amb jardins o arbres molt grans,...

L'objectiu és aconseguir obtenir una igual o millor classificació d'escenes en urbà i extraurbà d'una manera més senzilla

2.1.4 Classificadors en dia i nit

No existeixen treballs específics per a la classificació d'escenes en diürnes i nocturnes; és per això que s'haurà de desenvolupar una aplicació capaç de fer-ho el millor possible.

En tots els casos es produeixen falsos positius inevitables: jardins grans en zones urbanes, ambigüitat sobre què es pot considerar pluja o no pluja, problemes de classificació quan el cotxe s'introdueix en un túnel, ambigüitat sobre quan es considera que una imatge és nocturna i no diürna,...

3. Mètodes implementats

El classificador d'escenes usa un mètode eficient, en què amb molta rapidesa calcula els resultats de cada classificació un per un i en sèrie.

Més endavant s'explica detalladament quina sortida produeix l'algoritme i com s'ha d'usar.

En el diagrama de classes 3.1 es mostra com actua el classificador. La imatge d'entrada va sent analitzada algoritme per algoritme. Com es pot comprovar, cada imatge que vulguem classificar passarà pels quatre classificadors del projecte, i cada un d'ells donarà la sortida corresponent (és a dir, si correspon a un grup o a un altre). Finalment es recolliran els resultats de tots els algoritmes. Conseqüentment s'anirà seguint amb l'anàlisi amb totes les imatges que es vulguin classificar.

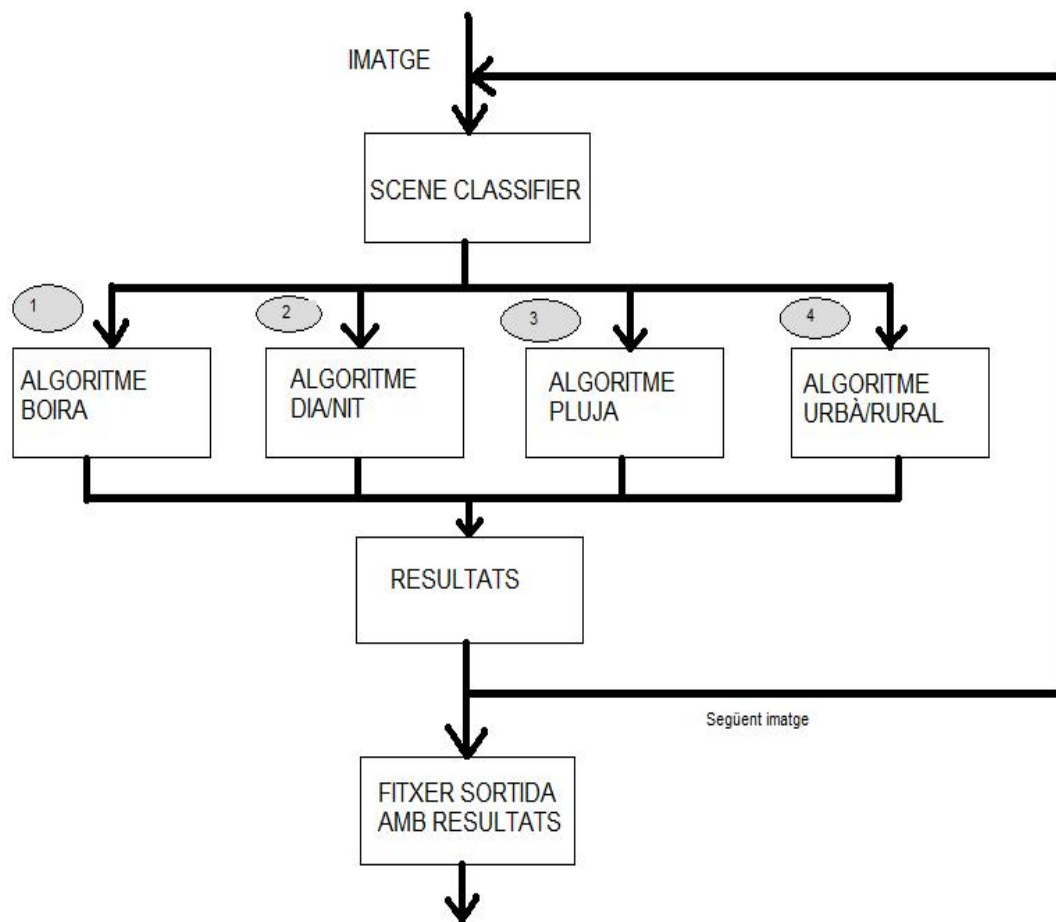


Diagrama de classes 3.1: imatge il·lustrativa de l'algoritme general

Separarem els mètodes en els 4 grups importants. S'explicaran amb detalls la implementació de cada un.

3.1 Algoritmes

3.1.1 Detecció de boira:

Si analitzem una imatge de boira podrem comprovar que, en funció també de la densitat de la boira, els objectes no es distingeixen bé. L'efecte boira produeix que, gradualment a la distància respecte l'observador, anem perdent definició i nitidesa amb tots els cossos que se'ns presenten fins a l'horitzó; tot fins que arriba un punt que la boira no permet veure més enllà.

Dit això, ens basarem en un supòsit important: fins a quin punt som capaços de distingir les cantonades dels objectes? L'objectiu de la poder classificar eficientment les imatges que contenen boira i les que no serà la d'idear un algoritme que detecti les cantonades de tots els objectes i analitzi si es distingeixen suficientment per poder considerar que es tracta d'una escena sense boira.

En la imatge 3.3 i 3.4 següents es pot comprovar com actua l'anàlisi de cantonades (edges) en el cas d'una imatge boirosa i d'una sense boira. En la primera imatge es defineixen clarament els contorns i arriba gairebé a l'horitzó, mentre que en la segona no, i en prou feines es definien els objectes més pròxims.



Imatge 3.1: Imatge original



Imatge 3.3: Contorns



Imatge 3.2: Imatge boira



Imatge 3.4: Contorns amb boira

En el diagrama de classes 3.2 s'especifica visualment el recorregut de la imatge. Tal i com s'ha explicat, cada imatge que vulguem analitzar passarà per "detector de cantonades". Si som capaços de distingir almenys bastant bé els contorns del objectes llavors direm que no es tracta d'una imatge de boira. Si pel contrari, a mesura que ens anem allunyant de la posició de l'observador, el "detector de cantonades" té més dificultats en identificar i separar els objectes, llavors direm que es tracta d'una escena boirosa.

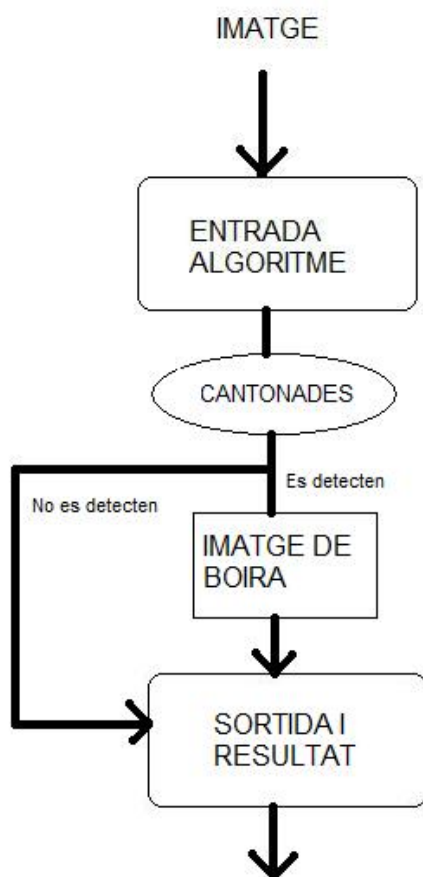


Diagrama de classes 3.2: algoritme de la classificació de la boira


3.1.2 Detecció de pluja:

Basarem l'algoritme en l'aprenentatge de gotes i semblança a elles, és a dir, separarem la classificació en les tres fases importants: entrenament, detecció de zones candidates i classificació de les imatges. L'algoritme es basa en la investigació portada a terme per Hiroyuki Kurihata i Tomokazu Takahashi [3].

S'ha usat el mètode d'entrenament/classificació "Suport Vector Machine (SVM)" que s'explica detalladament en l'apartat 3.2.1.

En el diagrama de classes 3.3 es mostra l'algoritme de classificació d'imatges en pluja o no pluja. Es pot veure les 3 fases principals:

- Entrenament gota a gota. Com més gran sigui la base d'entrenament de gotes, segurament millors resultats obtindrem a l'hora de classificar les escenes.
- detecció de possibles zones de gotes o plujoses. Anirem recorrent regió a regió de la imatge en la cerca de possibles candidates a gotes o zones mullades o de pluja. Les anirem comptant.



Imatge 3.5 Imatge partides en regions d'interès

Agafant com a exemple la imatge 3.5 anterior (les regions en aquest exemple no estan dividides al tamany real usat en l'algoritme), la qüestió és dividir la imatge en X regions d'interès (si pot ser totes del mateix tamany que les gotes d'entrenament) i anar-les processant una per una per veure si són candidates o no.

- classificació de les gotes i les escenes. Un cop processades totes les regions de la imatge es decidirà si es tracta d'una imatge de pluja o no.

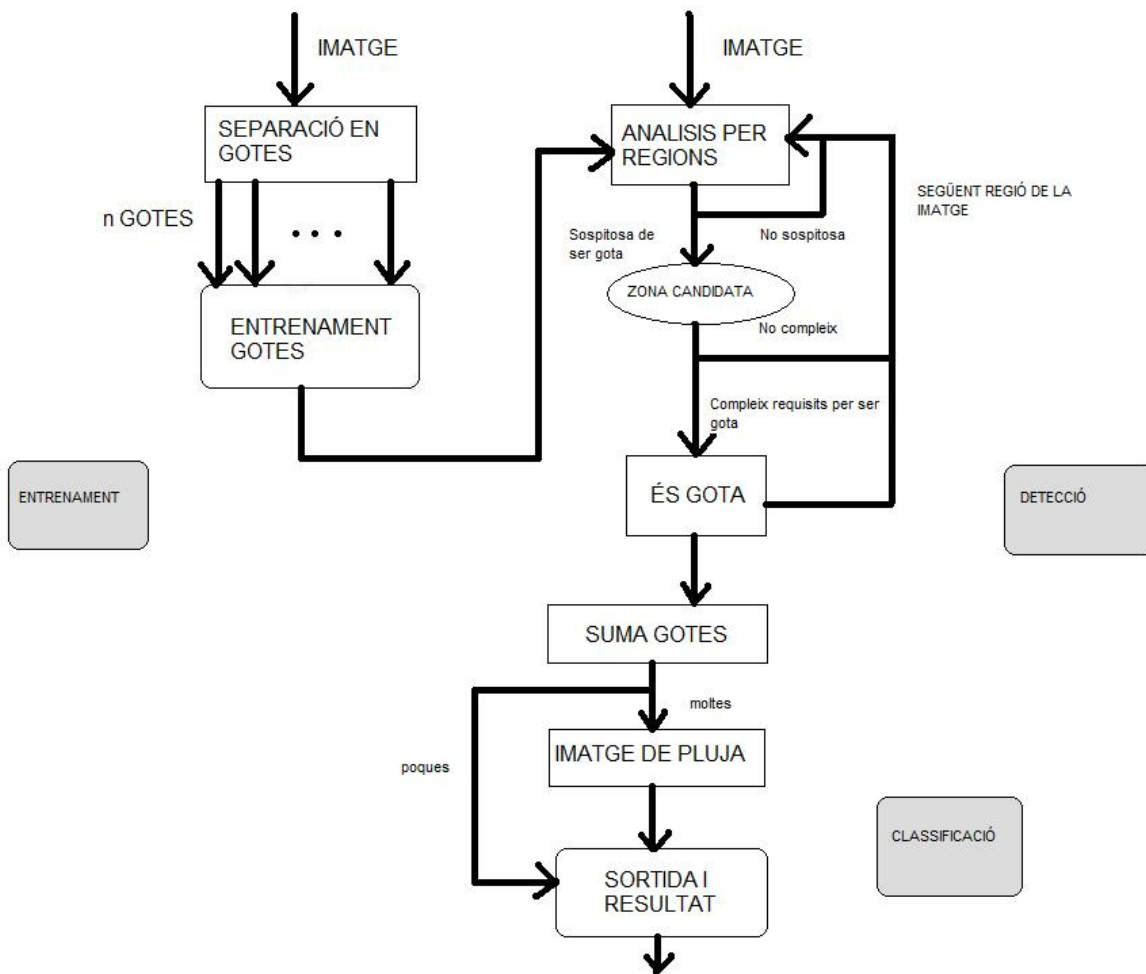


Diagrama de classes 3.3: algoritme de detecció de pluja

3.1.3 Classificació en zona rural i urbana:

Separarem la classificació en una fase d'entrenament de descriptors característics de les imatges i una fase classificació i testeig. Es basarà en la tècnica utilitzada per Thulasiraman i Prakash [1] de separació de zones urbanes i rurals.

S'ha usat el mètode d'entrenament "Suport Vector Machine", que s'explica detalladament en l'apartat 3.2.1.



Imatge 3.6

Textura=1.26
Hue=0.47
Valor color=0.416
Variància=0.08
Contorns=0.118
Tipus=urbana



Imatge 3.7

Textura=1.60
Hue=0.55
Valor color=0.575
Variància=0.087
Contorns=0.1425
Tipus=urbana



Imatge 3.8

Textura=1.389
Hue=0.297
Valor color=0.792
Variància=0.018
Contorns=0.105
Tipus=rural



Imatge 3.9

Textura=1.296
Hue=0.414
Valor color=0.678
Variància=0.066
Contorns=0.086
Tipus=rural

Les imatges anteriors mostren els valors calculats per tal de ser classificats mitjançant la base d'entrenament.

En el diagrama de classes 4 es mostra les dues fases, l'anàlisi de descriptors per l'entrenament SMV i la classificació de cada imatge en funció d'aquests descriptors.

Els descriptors usats pel Support Vector Machine són la tripleta HSV (és a dir, Hue, Saturation i Value of Colour), la textura de la imatge i la detecció de cantonades i contorns dels objectes.

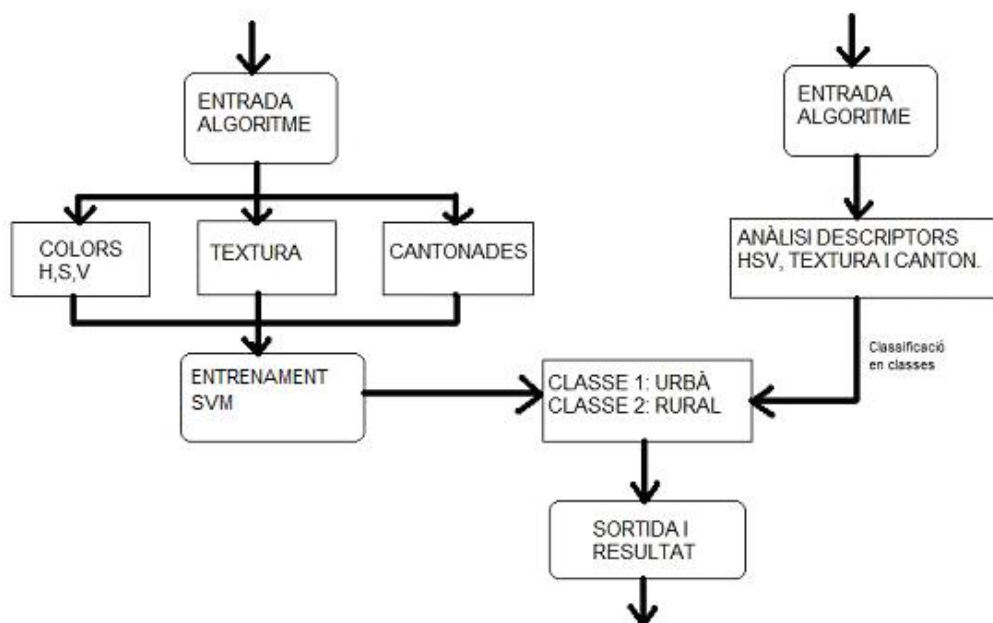


Diagrama de classes 3.4: classificació zones urbanes i extraurbanes

3.1.4 Classificació en imatge nocturna i diürna:

Es calcula la mitjana de color de la imatge sencera. Amb aquest valor diferenciem tres casos:

- Imatge fosca. Es tractarà d'una imatge de nit.
- Imatge clara:
 - o Imatge nocturna però amb molts punts de llum o molt il·luminada.
 - o Imatge diürna.

Es comptabilitzaran quantes zones fosques, zones clares i zones de variància alta té la imatge. Anem a explicar en què consisteixen aquests 3 valors, donada la següent imatge,



Imatge 3.10: imatge nocturna de mostra

Entenem per zones fosques una regió com aquesta:



Imatge 3.11: zona fosca de la imatge 3.10

Per zones clares una regió com aquesta:



Imatge 3.12: zona clara de la imatge 3.10

I per zones de variància alta una regió com aquesta:



Imatge 3.13: zona de variància alta de la imatge 3.10

En les 3 imatges següents es pot comprovar els 3 casos exposats:



Imatge 3.14

Color=129.61

Zones fosques=0

Zones clares=26

Imatge 3.15

Color=29.63

zones fosques=no cal

zones clares= no cal

Imatge 3.16

Color=52.36

zones fosques=225

zones clares=35

Zones variància alta=280

Els valors anteriors ens demostren que la imatge 3.14 és de dia ja que principalment no té zones fosques i la mitjana de color de tota la imatge és bastant alta.

En la imatge 3.15, el valor mitjà de color és molt baix, per això parlem de que es tracta d'una escena nocturna.

La imatge 3.16 té una mitjana de color moderada, però conté moltes regions molt fosques i uns quanta punts de llum, a part, hi ha moltes zones de variació alta, per tant, estem parlant d'una escena nocturna també.

En el diagrama de classes 3.5 següent es mostra el recorregut de l'algoritme:

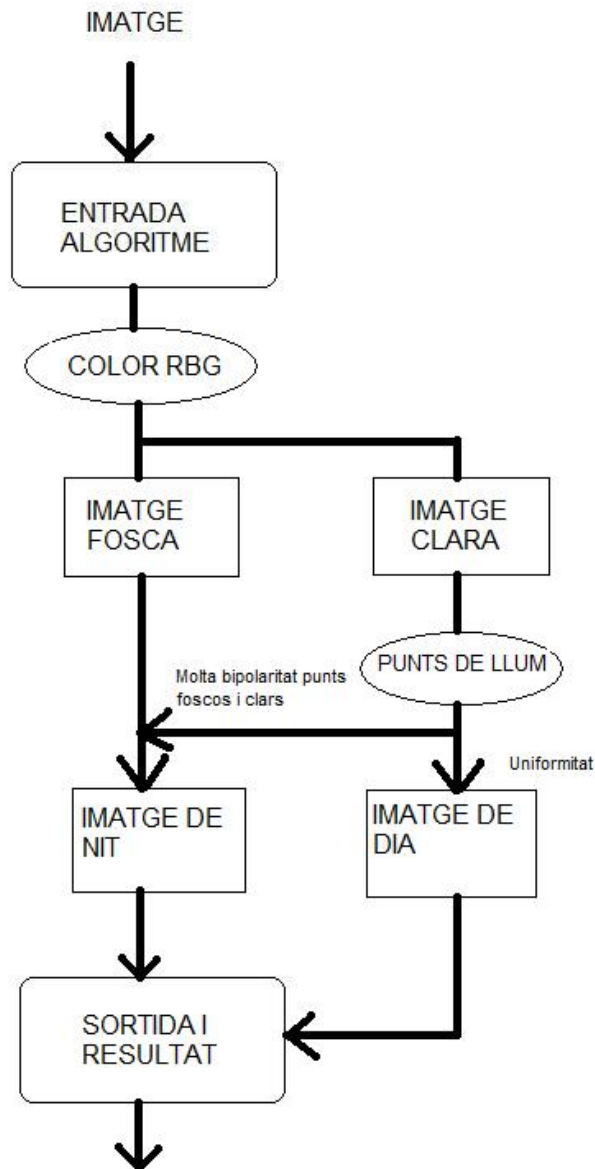


Diagrama de classes 3.5: classificació en imatges de dia i de nit

3.1.5 Fitxer de sortida:

L'algoritme, un cop processat i finalitzat, avoca els resultats de fitxer de text pla on s'indica per cada classificador la seva sortida.

El sub-apartat 4.4.5 explica amb més detalls i mostra un exemple de com funciona el fitxer de sortida.

3.2 Mètode d'entrenament/classificació


3.2.1 Support Vector Machine (SVM)

Aquest mètode supervisat intenta construir un hiperplà separant dues classes en un espai n-dimensional. Dos hiperplans paral·lels al principal són construïts entre les dues classes.

Donats uns descriptors d'entrada i unes indicacions sobre a quina classe pertanyen, la màquina intenta buscar d'hiperplà que millor les diferenciï per poder després classificar una nova entrada que no sigui d'entrenament en una classe o en una altra.

Aquest és el mètode d'entrenament més adequat pel projecte, tant per l'algoritme de les gotes com pel de zona urbana/rural, ja que només necessitem diferenciar entre si pertany a una classe o a una altra.

És per això, que s'ha usat per a les gotes en l'algoritme de detecció de la pluja i en la classificació en zona rural i urbana.



Imatge 3.17 Support Vector Machine

3.3 Detecció de cantonades

3.3.1 Filtre de Prewitt i de ZeroCross

S'ha usat els filtres de Prewitt i de "ZeroCross" per a poder comprovar com de fàcil es podien diferenciar els objectes tot comprovant-ne les cantonades.

Les figures 3 i 4 del mètode de detecció de boira mostren un exemple gràfic del seu comportament.

Prewitt:

Prewitt és un mètode que calcula la màxima resposta d'una sèrie de convolucions per així trobar l'orientació de les cantonades per a cada píxel. Es basa en aplicar un filtre horitzontal i un de vertical en la seqüència de píxels. És apropiat per estimar la magnitud i l'orientació d'una cantonada.

Zero Cross:

Aquest mètode busca punts en la Laplaciana de la imatge on el valor d'aquesta canvia de signe (és a dir, creua el valor 0). D'aquí ve el nom de Zero-Crossing, de creuar el 0.

Aquests punts acostumen a passar en zones amb cantonades.

4. Experiments

Per portar a terme els experiments del projecte hem seleccionat un conjunt d'imatges d'escenes exteriors i de carretera; són fotografies tirades amb una càmera des de l'interior del cotxe i mirant endavant.

4.1 Base de Dades

Per tal de poder usar les imatges en els experiments, aquestes havien de complir una sèrie de requisits:

- Han de ser escenes exteriors. N'és una condició de l'objectiu propi del projecte.
- Han de contenir carretera. També forma part de l'objectiu del projecte.
- Han de ser tirades des de dins del cotxe o simular ser tirades des de dins del cotxe (a una alçada i condicions semblants).
- Han de ser imatges ben enfocades, sense contenir textos informatius de les imatges i sense errors.
- Han de ser imatges en format jpg o jpeg.

Per a la realització d'experiments, entrenaments i testejos dels algoritmes s'ha usat imatges extretes de 3 sectors diferents:


A l'hora d'escollir les imatges vàlides és difícil de trobar ja que han de complir els requisits anteriorment explicats.

Hem utilitzat les escenes per fer experiments parcials de cada algoritme. Exemples correctes de cada cas:

Algoritme de dia/nit



Imatge 4.1: Exemples d'imatges de dia



Imatge 4.2: Exemples d'imatges de nit

Es pot comprovar que les imatges de la imatge 4.1 mostren escenes diürnes i sense ambigüitat. El Sol hi és present. La última imatge d'aquesta imatge i altres que sigui semblants en horari es consideraran imatges de dia per evitar confusions.

Les imatges de la imatge 4.2 anterior correspon a una escena urbana i nocturna, el Sol ja no hi és i es pot distingir el cel de nit i els fanals del carrer encesos.

Algoritme de boira



Imatge 4.3: conjunt d'imatges de mostra en què hi ha boira



Imatge 4.4: conjunt d'imatges d'exemples sense boira

Les imatges de la imatge 4.3 corresponen a escenes amb boira. A mesura que busquem objectes més llunyans es fa més difícil distingir-ne els contorns, fins que arriba un punt, és el cas sobretot de la imatge 3, que no veiem l'horitzó.

Les imatges de la imatge 4.4 corresponen a escenes sense boira ja que es distingeixen perfectament els contorns de tots els objectes, fins i tot els que es troben a una distància força considerable.

Algoritme de urbà/rural



Imatge 4.5: Conjunt d'imatges que escenifiquen paisatges rurals



Imatge 4.6: Conjunt d'imatges que escenifiquen zones urbanes


Les imatges de la imatge 4.5 anterior corresponen a escenes rurals. Entenem com a escenes rurals no pas escenes a l'interior d'un poble, sinó imatges en que no hi ha, o hi ha poques, edificacions de qualsevol tipus. Es distingeixen aquestes escenes de les urbanes pel fet, per exemple, de no tenir cap edificació al costat de la carretera, de tenir colors més vius als voltants (vers, ocres,...).

Les imatges de la imatge 4.6 anterior corresponent a imatges urbanes, ja que contenen principalment edificacions i objectes urbans. És fàcilment distingible, sobretot, pels colors (tonalitats grises) i per uns contorns (cantonades) més ben definits.

Algoritme de pluja



Imatge 4.7: exemples d'imatges amb pluja



Imatge 4.8: conjunt d'imatges no plujoses

Les imatges de la imatge 4.7 anterior corresponen a escenes de pluja ja que contenen elements que ho demostren: gotes al vidre, gotes que es veuen físicament com cauen i els contorns dels objectes perden definició.

Les imatges de la imatge 4.8 anterior corresponen a escenes en què no plou. No hi cap indicatiu de pluja en cap d'elles, no es veuen gotes i els contorns estan ben definits, a no sé que corresponguin a una escena de boira (que en aquest cas no són)

4.2 Imatges rebutjades

Separarem en dos casos les imatges rebutjades, les de caire general i les específiques de cada algoritme.

Es consideren imatges no útils per fer experiments, ni testeig, ni validar el classificador els següents exemples generals:

- Imatges mal enfocades. És a dir, imatges en què no s'arriben a distingir amb claredat els objectes (i no per l'efecte de la boira) per culpa d'un desenfocament de la càmera o pel moviment amb la velocitat del vehicle. En la imatge 4.9 següent es pot comprovar que la imatge no està gaire ben enfocada:



Imatge 4.9

- Imatges amb modificacions no reals. És a dir, imatges amb capçaleres afegides artificialment, amb objectes dibuixats, amb qualsevol modificació respecte de la imatge original. En la imatge 4.10 següent es pot veure que se li ha afegit després de processar-la una capçalera blanca amb un text a la part inferior esquerra:



Minnesota DOT

Imatge 4.10

Cal puntualitzar que considerarem imatges rebutjables aquelles que no ens siguin útils per fer les proves de testeig, això no vol dir que si una imatge no compleix els requisits no pugui tenir els resultats adequats (per exemple, una imatge de boira sense ser escena de carretera, al processar-la a l'algoritme també ens dirà que és de boira).

Els tipus d'imatges no usades per cada classificador són:

- Classificació de boira: cap condició especial excepte les generals exposades en l'apartat 4.1.

- Classificació dia/nit: s'han rebutjat les imatges d'escenes de carretera situades a l'interior de túnels. La imatge 4.11 és un exemple de túnel, no hi ha cap indicati sobre l'estat actual del temps ni de si és de dia o de nit.



Imatge 4.11

- Classificació rural/urbà: cap condició especial excepte les generals anteriorment exposades.

- Classificació pluja: s'han rebutjat les escenes que no contenen almenys una part de l'asfalt i que no siguin "on-road". La imatge 4.12 mostra una escena urbana no vàlida ja que no és de carretera.



Imatge 4.12

4.3 Parametrització de cada algoritme

Algoritme de la boira:

Aquest algoritme, tal i com ja s'ha explicat, busca les cantonades. Per fer-ho s'ha aplicat 2 filtres de manera independent:

- Filtre de Prewitt: s'ha considerat com a valor límit (llindar) el 0.05
- Filtre de ZeroCross: s'ha considerat com a valor llindar el 0.002

En l'apartat 3.3.1 s'expliquen els dos filtres.

Algoritme de la pluja:

Per aquest algoritme s'han considerat dos paràmetres importants:

- Percentatge de zones de pluja: això no vol dir quantitat de gotes respecte tots els píxels. Aquest paràmetre defineix quin percentatge de tota la imatge correspon a zones sospitoses de formar part d'una escena de pluja. Es va calcular comptant quantes regions de la imatge són propenses a ser de pluja. S'ha considerat que el llindar límit era del 25% (0.25).

- Filtre ZeroCross: s'ha aplicat, igual que a l'algoritme de la boira, un filtre per detectar les cantonades, ja que quan plou es difuminen. S'ha considerat el valor límit de 0.004, major que en la boira ja que la difuminació no acostuma a ser tan alta.

En l'apartat 3.3.1 s'explica el filtre de ZeroCross.

Algoritme de zona rural/zona urbana:

Per tal de poder fer l'entrenament amb SVM (Suport Vector Machine), s'han considerat que els descriptors més importants d'una imatge eren la textura (dimensió fractal), la mitjana de color, la variància de colors, i el llindar de les cantonades.

Per cada imatge es calculaven aquests 4 paràmetres i es decidia si pertanyien a una classe o a una altra.

Algoritme de classificació dia/nit:

En aquest procés s'han usat els següents paràmetres:

- Zones fosques: es comptabilitzaven quantes regions de la imatge es consideraven "fosques". Per considerar que una zona era fosca es prenia com a valor que la mitjana de color per aquella regió era menor que 40.

- Zones clares: es comptabilitzaven les zones clares com a punts de llum. Per considerar que ens trobàvem amb un punt de llum preniem com a valor que la mitjana de color per aquella regió era major que 200.

- Zones de variància alta: es buscaven les regions en què hi havia molta diversitat de color (molta variància). Es considerava que una regió era zona de variància alta si la mitjana de la variància per aquell tros superava el valor 100.

Amb aquests 3 paràmetres principals es compatibilitzaven totes les regions que compleixen almenys un dels 3 requisits anteriors, i amb ells es decideix si la imatge és de nit o de dia.

En l'apartat 3.1.4 es mostren exemples dels 3 tipus de zones que es consideren.

Resum dels paràmetres més importants usats:

CLASS/PARAMS	FILTRE PREWITT	FILTRE ZEROCROSS	REGIONS PLUJA	ZONES F.,CLARES	MITJA COLOR	TEXTURA
BOIRA	X	X			X	
DIA/NIT				X	X	
RURAL/URBÀ	X				X	X
PLUJA		X	X		X	

Taula 4.1: Paràmetres

4.4 Resultats

A continuació presentarem els resultats de cada algoritme i del projecte en general, així com percentatges d'eficiència, resultats parcials i temps.

S'ha testejat cada part amb un conjunt de 216 imatges aleatòries.

La Taula 4.2 següent mostra tots els resultats de l'aplicació, desglossades per algorismes, i el seu temps de processament:

Tipus de classificació	Imatges del tipus	Ben classificades	Percentatge d'encert	Temps total	Temps per imatge
Imatges amb boira	12	11	91.67		
Imatges sense boira	261	232	88.89		
Classificació boira	273	243	89.01		
Imatges de dia	231	208	90.00		
Imatges de nit	39	32	82.05		
Classificació nit	273	240	87.91		
Imatges de zones urbanes	89	86	96.63		
Imatges de zones no urbanes	127	70	55.12		
Classificació urbanes	216	156	72.23		
Imatges amb pluja doble edge	31	1	20		
Imatges sense pluja doble edge	211	165	78.20		
Classificació pluja doble edge	242	166	68.18	17'	4.21
Imatges amb pluja single edge i params mod	37	27	72.98		
Imatges sense pluja single edge params mod	236	114	48.31		
Classificació pluja single edge i params mod	273	141	51.65	16'	3.51
Imatges amb pluja single edge i params mod2	32	17	53.13		
Imatges sense pluja single edge param mod2	211	105	49.76		
Classificació pluja single edge i params mod 2	243	122	50.21	14'	3.51
Total Imatges (combinacions cada tipus)	215	140	65.12		
Total Imatges (resta combinacions)	817	640	78.34		
Total absolut	1032	780	75.58		3.51

Taula 4.2: Taula representativa de tots els resultats de l'algoritme

Les imatges de testeig contenen:

- Per l'algoritme de la boira: 12 imatges amb boira i 261 sense. La taxa de d'encert per aquest algoritme és d'un 89.01% aproximadament.
- Per l'algoritme de dia/nit: 231 imatges de dia i 39 de nit. La taxa d'encert per aquest algoritme és del 87.91% aproximadament.
- Per l'algoritme de la pluja: 37 imatges amb pluja i 236 sense. La taxa d'encert per aquest algoritme és del 51.65% aproximadament, essent els falsos positius en la classificació d'imatges sense pluja el detonant d'aquest percentatge.
- Per l'algoritme de zona rural/urbana: 89 imatges urbanes i 127 d'extraurbanes. La taxa d'encert per aquest algoritme és del 72.23% aproximadament.

La taxa d'encert final per cada algoritme (és a dir, bones classificacions de la pluja en l'algoritme de la pluja, zona rural pel rural, nit per l'algoritme de dia/nit i boira pel de boira) és del 65.12%.

Per tant, la **taxa d'encert final del projecte és del 75.58%**, amb una ponderació de 780 bones classificacions sobre 1032 imatges de mostra.

Pel que fa al temps de processat, aquest va ser de 16 minuts per a totes les imatges, essent el temps mitjà de classificació per imatge de 3.51 segons. Per tal de millorar el temps de processat s'ha usat tècniques especials, com per exemple només usar la meitat o una tercera part dels píxels d'una imatge. D'aquesta manera, funcions especials que requerien un temps inevitablement més elevat del previst s'han pogut reduir substancialment.

4.4.5 Fitxer de resultats

Per cada classificador indica amb un "0" si la imatge corresponent no pertany a aquell tipus i amb un "1" si afirmativament hi pertany. La imatge 1 següent seria un exemple de fitxer de sortida de resultats.

El fitxer conté una fila per imatge, les quals enumera per ordre ascendent començant per la número 1.

Notació: per tal de provar el projecte, les imatges estaran contingudes en la carpeta /Test4, hauran de ser de format .jpg, .jpeg, .JPG o .JPEG, i per millorar-ne l'eficiència s'anomenaran x.jpg (o .jpeg,...) començant per x=1 i en ordre ascendent (igual que el fitxer de resultats).

Imatge	Boira	No_Boira	Dia	Nit	Pluja	No_Pluja	Urban	Rural	Referència
Imatge 1	--> 0	1	0	1	0	1	1	0	<--Imatge: 1
Imatge 2	--> 0	1	0	1	1	0	1	0	<--Imatge: 2
Imatge 3	--> 0	1	1	0	1	0	0	1	<--Imatge: 3
Imatge 4	--> 0	1	1	0	0	1	0	1	<--Imatge: 4
Imatge 5	--> 0	1	1	0	0	1	1	0	<--Imatge: 5
Imatge 6	--> 1	0	0	1	1	0	1	0	<--Imatge: 6
Imatge 7	--> 0	1	0	1	1	0	0	1	<--Imatge: 7
Imatge 8	--> 1	0	0	1	1	0	0	1	<--Imatge: 8
Imatge 9	--> 1	0	0	1	1	0	0	1	<--Imatge: 9

Imatge 4.17: Fitxer de resultats finals

En la imatge anterior si agafem com a mostra la imatge 1 del fitxer, ens està indicant que es tracta d'una escena sense boira, nocturna, sense pluja i urbana. La imatge que estava analitzant era la imatge 4.18 següent:



Imatge 4.18: imatge de prova pels resultats

4.5 Experiments parcials i alternatives descartades

Es van realitzar una sèrie de testejos per tal de trobar si la opció desenvolupada era la millor eficientment parlant.

La taula 4.3 següent es mostra tots els experiments realitzats amb els paràmetres, mètodes d'entrenament i demés de l'algoritme de classificació en zona rural i urbana.

Es van provar diverses combinacions amb una base de 90 imatges, una de 107, amb una altra de 156 i amb una quarta de 200.

Sobre cada una s'analitzaven els resultats, es mirava si a l'augmentar la base de dades milloraven els resultats o empitjoraven.

Les combinacions que donaven uns resultats pitjors s'anaven descartant per fer els experiments.

Al final es demostrava que l'opció escollida per al desenvolupament era la que millor resultats donava a l'augmentar la base de dades.

RURAL DATABASE	URBAN DATABASE	CLASSIFICATION	PERCENTAGE OK
66	24	HSV, VAR HSV, DIM FRACTAL	0.7222
66	24	HSV, DIM FRACTAL	0.7111
66	24	HSV	0.7111
66	24	DIM FRACTAL	0.7333
66	24	DIM FRACTAL, V (VALUE COLOR)	0.7333
66	24	DIM FRACTAL, V, H	0.7333
66	24	DIM FRACTAL, V, VAR V	0.7
66	24	DIM FRACTAL, V, VAR H	0.7111
66	43	HSV, VAR HSV, DIM FRACTAL	0.68807
66	43	HSV, DIM FRACTAL	0.6789
66	43	HSV	0.68807
66	43	DIM FRACTAL	0.6055
66	43	DIM FRACTAL, V (VALUE COLOR)	0.6422
66	43	DIM FRACTAL, V, H	0.69725
66	43	DIM FRACTAL, V, VAR V	0.70642
66	43	DIM FRACTAL, V, VAR H	0.6422
66	43	V	0.6422
66	43	VAR V	0.63303
100	56	HSV, VAR HSV, DIM FRACTAL	0.71154
100	56	HSV, DIM FRACTAL	0.71795
100	56	HSV	0.71154
100	56	DIM FRACTAL	0.64103
100	56	DIM FRACTAL, V (VALUE COLOR)	0.66667
100	56	DIM FRACTAL, V, H	0.6859
100	56	DIM FRACTAL, V, VAR V	0.69231
100	56	DIM FRACTAL, V, H, EDGES	0.77564
100	56	HSV, VAR HSV, DIM FRACTAL, EDGES	0.73077
100	56	DIM FRACTAL, V, VAR V, EDGES	0.77564
100	100	DIM FRACTAL, V, H, EDGES	0.735
100	100	HSV, VAR HSV, DIM FRACTAL, EDGES	
100	100	DIM FRACTAL, V, VAR V, EDGES	0.72
90	93	DIM FRACTAL, V, VAR V, EDGES	0.82514

Taula 4.3: Testos parcials per l’algoritme de classificació d’urbà i rural, on DIM FRACTAL representa la dimensió fractal, HSV l’espai de colors HSV (hue, saturation, value) i VAR X la variància

La taula 4.4 mostra dos experiments diferents provats per l’algoritme de la pluja. Es va voler provar si aplicant conceptes de la dimensió fractal de la imatge i la variància de color en les regions de la imatge augmentarien la seva eficiència. No va ser així, al contrari, els resultats no van ser dolents, però van ser pitjors que el simple càlcul del valor mitjà del color. A part, el temps per a calcular els 3 paràmetres per cada regió de l’escena era molt més alt, fent que l’algoritme tardés bastants minuts a processar una sola imatge.

GOTES DATABASE	NO_GOTES DATABASE	CLASSIFICATION	PERCENTAGE OK	TESTING
	70	DIM FRACTAL, V, 65 VAR V	0.70296	MALAMENT
	70	65 VALORS PIXELS	0.78519	OK

Taula 4.4: testos parcials algoritme de la pluja

Es van realitzar altres experiment tot buscant el mètode d'entrenament més eficient, entre ells es va provar d'usar x'arxes neuronals, però aviat es va veure que usant Support Vector Machine obtindriem millor resultats per la classificació sempre en 2 classes.

5. Comparativa de resultats

En aquesta secció farem una comparativa de resultants i de demostració d'eficiència entre la solució presentada i altres projectes semblants. Com en les seccions anteriors desglossarem la comparativa en la comparativa de cada classificador amb classificadors semblants.

Classificació de la boira:

Donades les limitacions de Hautière, Jean-Philippe Tarel, Jean Lavenant, Didier Aubert i per altra banda Yi-Shu Zhai, Xiao-Ming Liu, en què requereixen que la imatge contingui almenys un tros de cel i un tros de carretera, la solució presentada proporciona uns resultants més generals i amb menors limitacions. Com es pot comprovar en la Taula 1 de resultants generals, l'eficiència del nostre classificador és d'un 89% sobre una base de 300 imatges aproximadament. Cal dir que, aquest percentatge també és extensible a imatges que no necessàriament tinguin carretera i/o cel.

Els classificadors de Hautière, Jean-Philippe Tarel, Jean Lavenant, Didier Aubert i per altra banda Yi-Shu Zhai, Xiao-Ming Liu, presenten una eficiència molt elevada també però limitant les condicions del classificador.

Classificació de rural/urbà:

Nosaltres hem proposat un algoritme, que mitjançant tècniques molt més senzilles i igualment eficients, podem classificar una escena en rural o urbana amb un percentatge del 72.3% amb imatges de tot tipus.

En els dos casos es produeixen falsos positius inevitables, com zones arbrades ben grans corresponents a jardins molt grans de cases.

Classificació de dia/nit:

Bé, donat que no existeix un projecte que es dediqui exclusivament a classificar les imatges en nocturnes i diürnes, amb els resultants de la Taula 1 es pot comprovar que la solució presentada té una eficiència en tots els aspectes molt elevada.

Un 88% de bones classificacions demostra que la nostra solució classificarà bé pràcticament sempre les imatges en nocturnes i diürnes. Donat un algoritme amb dues possibles solucions com el nostre (dia i nit), només es podrien produir falsos positius en casos ambigus per l'home (llum del vespre, a decidir si es tracta de dia o de nit), imatges en túnels i imatges nocturnes amb llum semblant a la del Sol.

És per això que presentem un algoritme molt fiable i eficient.

Classificació de la pluja:

Hiroyuki Kurihata i Tomokazu Takahashi [3] presentava un algoritme capaç de detectar i distingir les gotes i les imatges de pluja amb una eficiència del 70% aproximadament, però amb 1 supòsit important: necessiten punts de llum a la imatge (a part de ser imatges de carretera).

Nosaltres hem desenvolupat un algoritme capaç de classificar amb un 70% d'eficiència les imatges de tot tipus sense tenir cap pre-condició (a part de la de ser una imatge de carretera, és clar). Senzillament analitzem totes les regions de les imatges i busquem la semblança que tenen amb regions típicament de pluja. Dit això, el 70% de bones classificacions que presentem, demostra amb escreix la fiabilitat del nostre projecte.

6. Conclusió

6.1 Discussió de resultats

Amb la realització del projecte s'ha fet palès que la detecció de pluja és difícil i ambigua, ja que moltes vegades ni l'ull humà és capaç de veure les gotes en una escena. L'ambigüitat rau en el fet de com decidir que plou o no plou, és a dir, una escena amb el terra moll és de pluja? Una escena seca però que cauen gotes és escena de pluja? Una escena en què plou poc és una escena de pluja? Una escena en què no es veuen les gotes però creiem que plou és una escena de pluja?

Aquestes mateixes preguntes han dificultat l'execució de l'algoritme.

Tot i així, es pot considerar que els resultats del classificador, tant a nivell d'eficiència d'encert com en temps, són molt satisfactoris.

6.2 Conclusió general

La planificació prevista s'ha pogut complir. La fase de recopilació de la informació i escollir com implementar cada algoritme en alguns casos s'ha allargat més del compte.

Un cop complertes totes les fites previstes en la planificació del projecte és hora de treure'n conclusions i analitzar els resultats de la feina feta respecte dels objectius inicials.

L'objectiu principal del projecte era la classificació d'imatges adquirides des de la plataforma mòbil per l'òptima utilització d'altres algoritmes de visió.

S'ha plantejat un algoritme capaç de classificar una imatge d'entrada en cada una de les 8 classes definides.

Els resultats obtinguts suggereixen que mitjançant tècniques de visió artificial es pot aconseguir classificar una imatge de carretera d'una manera eficient.

6.3 Treball futur

Amb la realització del projecte han quedat aspectes a desenvolupar com a treball futur.

Un d'ells és el de considerar eficientment les imatges de vespre, és a dir, aquelles que no es poden incloure com a imatges nocturnes ni diürnes.

Com a nivell general i feina a desenvolupar més extensament, es podria extrapolar el classificador a escenes en general, és a dir, no necessàriament imatges "on road".

Un aspecte molt important, però també concret i difícil de tractar, és el de les escenes situades a dins d'un túnel. Ara per ara les classificacions en aquest cas són molt ambigües, ja que no es pot dir si és escena de dia o escena de nit, a no ser que es vegi clarament el final del túnel. En definitiva, és una qüestió a solventar.

6.4 Valoració personal

Crec que el fet de poder desenvolupar el projecte de forma continuada seguint una planificació ajuda a disfrutar més de la feina que estàs fent.

El camp de la intel·ligència artificial i la visió per computadora sempre m'han interessat. Sóc molt aficionat a la meteorologia. Unint aquests dos camps, quan vaig veure el projecte no vaig dubtar en agafar-lo.

Puc dir, que en aquest projecte he disfrutat molt i he après coses que mai m'hagués imaginat que es poguessin fer d'una manera.

Ha sigut una experiència molt enriquidora.

7. Referències

Prospectes

- [1] Thulasiraman, Prakash. 2005. Semantic Classification of rural and urban images using learning vector quantization. *B.E., Madras University.*
- [2] Kshitiz Garg and Shree K. Nayar. 2006. Vision and rain. *Department of Computer Science, Columbia University, New York..*
- [3] Hiroyuki Kurihata, Tomokazu Takahashi, Yoshito Mekada, Ichiro Ide, Hiroshi Murase. 2006. Raindrop Detection from In-Vehicle Video Camera Images for Rainfall Judgment. *Graduate School of Information Science, Nagoya University Furo-cho, Chikusa-ku, Nagoya, Japan*
- [4] Vision Image Processing Database. 2005. *Columbia University*
- [5] Nicolas Hautière, Jean-Philippe Tarel, Jean Lavenant, Didier Aubert. Automatic Fog Detection and Estimation of Visibility Distance through use of an Onboard Camera. *LIVIC, a joint INRETS-LCPC entity.*
- [6] Yi-Shu Zhai, Xiao-Ming Liu. An improves fog-degraded image enhancement algorithm. *School of Information Engineering, Dalian Maritime University, Dalian, Liaoning Province, China.*
- [7] Fang, Chen i Fuh. 2003. Automatic Change Detection of Driving Environments in a Vision-Based Driver Assistance System. *Department of Computer Science and Information Engineering, National Taiwan Normal University, Taipei, Taiwan, R.O.C, i IEEE.*

Referències Web:

- Wikipedia:

Rain. Autor: Wikipedia. 2009. URL: <http://en.wikipedia.org/wiki/Rain>

Fog. Autor: Wikipedia. 2009. URL: <http://en.wikipedia.org/wiki/Fog>

Support Vector Machine. Autor: Wikipedia. 2009 URL:
http://en.wikipedia.org/wiki/Support_vector_machine
Zero Crossing algorithm. Autor: Wikipedia. 2009. URL:
http://en.wikipedia.org/wiki/Zero_Crossing

- Autres:


Zero Crossing. URL: <http://homepages.inf.ed.ac.uk/zeros.htm>
Varis. Autor: IEEE. 2009. URL: <http://www.ieee.org/portal/site>

8. Apèndix

8.1 Base d'imatges usades per entrenament

Les següents imatges són, per una banda, exemples de gotes usades per a l'entrenament, i per l'altra, imatges corresponents a típiques zones de no pluja, també per a l'entrenament.

Gotes de pluja:



Imatges de no gotes:



8.2 Dedicació i eines usades

Les eines utilitzades pel desenvolupament del projecte han sigut:

- Ordinador personal: processador Intel Pentium IV a 2,53 Ghz i memòria RAM de 512 Mb, disc dur intern de 100 Gb i extern de 500 Gb d'espai.
- Software necessari: MATLAB versió 7.4.0 (R2007a) amb les toolboxes necessàries instal·lades.
- Coneixements amplis en el camp de la Intel·ligència Artificial i la Visió per Computadora.

La dedicació del projecte ha sigut a temps complet d'octubre de 2008 a juny de 2009.

S'ha separat la viabilitat del projecte en la viabilitat de cada part:

- Estudi detecció boira: cerca de tota la informació possible d'algoritmes i idees sobre com detectar si una imatge és amb boira o no. No ha sigut necessari saber la distància a la qual es troba la boira.
- Estudi classificació dia/nit: com crear una algoritme suficientment robust perquè classifiqui les imatges amb la millor eficiència.
- Estudi detecció de la pluja: desenvolupament d'un algoritme amb mecanisme d'entrenament capaç de detectar les gotes o la pluja en una escena.
- Estudi classificació en imatges rurals/urbanes: ha sigut la part més complexa del projecte a causa de la diversitat i l'ambigüitat d'aquest tipus de classificació (jardins molt grans que pugui semblar escenes rurals,...)

Les eines d'ajuda més importants que s'han usat han sigut:

- Webs de recerca (www.google.cat, www.yahoo.com, Wikipedia).

- Ajuda pròpia del MATLAB.
- Universitat.
- Prospectes de classificació d'escenes, visió artificial, meteorologia, escenes de carreteres, efectes visuals,... Ja sigui a l'IEEE o a universitats concretes tots buscant en els cercadors paraules clau o algoritmes que poguessin estar relacionats amb el projecte.

Dit això, la viabilitat del projecte ha caigut sobretot en la investigació per separat de cada part i el contrast amb tota la informació recopilada. L'èxit del projecte en part també ha caigut amb la correcta implementació del classificador d'escenes rurals i urbanes.

