

# Un sistema de Razonamiento Basado en Casos en el análisis de imágenes naturales

Xavier P. BURGOS-ARTIZZU

Instituto de Automática Industrial. Consejo Superior de Investigaciones Científicas  
28500 Arganda del Rey, Madrid, España

y

Angela RIBEIRO

Instituto de Automática Industrial. Consejo Superior de Investigaciones Científicas  
28500 Arganda del Rey, Madrid, España

## RESUMEN

La Agricultura de Precisión surge con el objetivo de mejorar la calidad de los cultivos, ahorrando en fitosanitario y consiguiendo con ello una reducción en los residuos que contaminan suelos, plantas y atmósfera. En este artículo se presenta una plataforma de ayuda al análisis de imágenes capaz de determinar de modo automático la cantidad de mala hierba a partir de fotos del cultivo. La parte central de la plataforma la constituye un sistema de razonamiento basado en casos que selecciona en cada imagen el método más adecuado de procesamiento. El funcionamiento del sistema desarrollado se verifica con un conjunto de imágenes obtenidas a partir de diferentes muestreos realizados sobre cultivos en distintos años y zonas. Este trabajo forma parte de un proyecto de investigación financiado por el Gobierno Español.

**Palabras Clave:** Análisis imagen, razonamiento basado en casos, agricultura de precisión, detección de mala hierba.

## 1. INTRODUCCIÓN

Las prácticas del cultivo tradicionalmente se han orientado hacia una gestión uniforme del campo ignorando la variabilidad espacial que aparece en los cultivos; lo que presenta fundamentalmente dos tipos de inconvenientes: a) contaminación de los suelos con la consecuente contaminación de las aguas subterráneas. y b) un notable aumento en el coste económico de la producción agrícola.

Es un hecho que cada campo de cultivo puede variar enormemente tanto en términos de composición de flora arvense como en su abundancia. El concepto de Agricultura de Precisión en contraposición a los métodos agrícolas tradicionales propone ajustar las dosis del tratamiento fitosanitario a las necesidades de cada unidad de terreno, en pocas palabras aplicar herbicida sólo en aquellas zonas en las que la densidad de mala hierba así lo aconseje.

En la actualidad existen pocos métodos de estimación de las poblaciones de malas hierbas que sean fácilmente utilizables por un agricultor o un técnico. El presente trabajo forma parte del desarrollo de un método de muestreo sencillo y de bajo coste que permite estimar eficazmente la cantidad de mala hierba en un punto a partir de una foto. El objetivo final es la generación

de un mapa de tratamiento en el que se indique dónde y en que dosis aplicar el herbicida.

El sistema desarrollado para la estimación de la cobertura de mala hierba tiene como entrada conjuntos de imágenes que provienen de muestreos fotográficos realizados en el campo en puntos que pueden o no ajustarse a una malla. El procesamiento que se realiza sobre cada imagen está dividido en distintas fases en las que, como veremos más adelante, hay que definir un conjunto de parámetros que aseguren el ajuste de los procedimientos a distintas condiciones, por ejemplo de iluminación. Dada una imagen, la decisión sobre que método usar en cada fase y cuales son los valores más adecuados para los parámetros del método se obtiene sin intervención del usuario a partir de un sistema Razonamiento Basado en Casos (CBR).

En el siguiente apartado se describe formalmente el problema y las características de las imágenes a procesar. En la sección 2 se analiza en detalle el procesamiento de imágenes propuesto, explicando los métodos desarrollados para cada etapa. En la sección 3 se examina el sistema CBR implementado. Los resultados más relevantes se presentan en la sección 4. Para finalizar, en la sección 5, se exponen las conclusiones más importantes.

## 2. DESCRIPCIÓN DEL PROBLEMA

Como se ha comentado el objetivo del sistema desarrollado es ayudar en la estimación en una foto de la cobertura de mala hierba expresada en tanto por ciento. De modo que a partir de la evaluación en varias zonas de un mismo campo de cultivo se pueda obtener un mapa de infestación utilizando alguna técnica de interpolación, como por ejemplo el kriging, donde los valores desconocidos se extrapolan a partir de los puntos vecinos, de forma que el valor de los puntos más cercanos tiene mayor influencia en la predicción que los valores de puntos más alejados [1].

Entre las dificultades que aparecen al desarrollar una herramienta de evaluación automática está el hecho de que especies frecuentes como la Avena sterilis o el Lolium rigidum tienen un aspecto indistinguible del cereal en fase inicial de crecimiento lo que dificulta el uso de técnicas convencionales de reconocimiento de patrones [2] o de clasificación de texturas naturales [3].

En estos casos, una buena estrategia para diferenciar el cereal de la mala hierba puede ser la posición, en otras palabras considerar infestación todo aquello que crezca fuera de las líneas de cultivo

Así el problema se traduce en localizar y separar del resto de la imagen las líneas de cultivo y contabilizar como mala hierba toda la cubierta vegetal que queda en la imagen. Este es un problema más sencillo pues las líneas cultivo tienen una forma geométrica estable y conocida, columnas verticales. Esta nueva perspectiva, aunque convierte el problema en abordable, no deja de presentar varias dificultades. Por ejemplo, la figura 1F, muestra un caso en el que la mala hierba está “conectada” al cultivo. Existen otros casos, como los que se muestran en las figuras 1E y 1H, en los que hay un error en el sembrado por lo que las líneas de cultivo no están claras. En otros casos el problema radica en el estadio de crecimiento del cultivo. Por ejemplo, en la figura 1C las líneas son prácticamente inexistentes, mientras que en las figuras 1B y 1G, son enormes. O incluso puede pasar, como se aprecia en la figura 1D, que una línea de cultivo sea más grande que otra.




Figura 1 - Ejemplos de imágenes de entrada

Otra cuestión a tener en cuenta es la iluminación, difícilmente controlable en exteriores, claro ejemplo de esto son las imágenes de la figura 1 en las que se aprecian evidentes diferencias de iluminación dependiendo de si el día en que se tomo la instantánea era o no soleado. Más aún incluso el color del suelo puede variar entre imágenes con las mismas condiciones de iluminación en función del grado de humedad. En resumen para obtener resultados globalmente satisfactorios es preciso desarrollar un sistema robusto y flexibilidad ante todas estas situaciones.

### Procesamiento de imágenes propuesto

Las fotos que se han utilizado como conjunto de partida corresponden a diferentes muestreos realizados con malla rectangular de dimensiones  $n \times m$  en campos de cereal de invierno. La posición de los puntos de muestreo (latitud, longitud) con un error inferior a un metro la suministró un receptor GPS diferencial de doce canales y se guardó utilizando una aplicación de ayuda a la recogida de datos georeferenciado desarrollada por el equipo[4]. Todas las imágenes fueron tomadas con un trípode, situando la cámara en posición vertical con respecto al suelo.

Además la presión de mala hierba, que es un valor fundamental a la hora de ajustar las dosis de tratamiento, se calcula como una relación entre el tanto por ciento de mala hierba, el tanto por ciento de cultivo y el porcentaje de suelo [5]. Por tanto es imprescindible estimar cada una de estas cantidades a partir de la imagen.

En la figura 2 se resumen las distintas etapas involucradas en el procesamiento de las imágenes. Dada una imagen de entrada en color, después de aplicar el índice descrito en [5] y transformarla en una imagen en escala de grises, se segmenta obteniendo una imagen en blanco y negro, donde el blanco corresponde a los píxeles pertenecientes a la cobertura vegetal




Figura 2 – Ejemplo de procesamiento de una imagen (malas hierbas y cultivo), y en negro a los píxeles de la imagen que son fondo o suelo. En la segunda etapa se determinan las zonas de píxeles a blanco que corresponden a las líneas del cultivo y se eliminan, identificando como mala hierba el conjunto de píxeles blancos que permanecen en la imagen. Para

mejorar los resultados y obtener una mayor exactitud, se ejecuta una tercera etapa, donde se elimina el ruido y se filtran los posibles errores de la etapa de eliminación de cultivo.

Para cada una de las etapas anteriormente descritas se han desarrollado y probado diferentes procedimientos en concreto 2 métodos distintos de segmentación, 3 de eliminación y otros 3 de filtrado. En la figura 3 se presentan algunos ejemplos de la ejecución de los distintos métodos en cada una de las etapas. Las figuras 3A y 3B muestran el resultado obtenido al aplicar los métodos de segmentación S1 y S2 respectivamente. Se puede observar que las imágenes resultantes son muy parecidas, aunque no idénticas. Las figuras 3C, 3D y 3E muestran, respectivamente, el efecto de la aplicación sobre la imagen segmentada de los métodos de eliminación E1, E2 y E3. En las figuras 3F, 3G y 3H se puede ver el resultado de la ejecución de los métodos E1, E2 y E3 de eliminación de líneas de cultivo en situaciones de una gran cobertura vegetal. En el primer caso se comprueba que los métodos E2 y E3 mejoran el resultado suministrado por el método E1. Además en las últimas imágenes se puede comprobar como en una situación conflictiva el método E1 elimina toda la cobertura vegetal y no sólo las líneas de cultivo mientras que los métodos E2 y E3 son capaces de discriminar entre cultivo y mala hierba aislando esta última. Las figuras 3I, 3J y 3K muestran, los resultados de ejecutar los métodos de filtrado F1, F2 y F3 sobre una imagen en la que ya




Figura 3 – Ejemplo de ejecución de los métodos

se han eliminado las líneas de cultivo. En resumen hay claras diferencias en los resultados según el tipo de imagen siendo unos métodos más adecuados así como los parámetros elegidos un factor determinante a la hora de alcanzar una detección una discriminación adecuada en la imagen entre mala hierba, cultivo y suelo.

### 3. EL SISTEMA CBR

Basándonos en el trabajo presentado en [6][7], se puede concluir que el tipo de imágenes recogidas en los distintos muestreos tiene características que se ajustan bien al desarrollo de un sistema CBR como modo de selección automática en cada etapa del método y los parámetros más convenientes.

#### Arquitectura global del sistema

El CBR desarrollado sigue un ciclo de procesamiento clásico (*Recuperación-Reutilización-Validación-Aprendizaje*), incluyendo al principio una clasificación por indexación de los casos. La clasificación divide la consulta (y los casos) en clases disjuntas, donde cada clase representa condiciones similares ante un conjunto característico de atributos de la imagen. Una vez realizada la clasificación, el sistema recupera el caso de la clase que presenta un mayor grado de similitud con la imagen de entrada, usando técnicas de análisis de similitud entre imágenes. A continuación, el sistema procesa la imagen de entrada asociada a la consulta, usando exactamente el mismo conjunto de métodos y valores de parámetros que se usó en el caso recuperado, obteniendo así el valor del tanto por ciento de cobertura de mala hierba y cultivo además del tanto por ciento de suelo. Finalmente, si la diferencia de similitud con la imagen recuperada supera un umbral fijado por el usuario, el sistema puede aprender de este nuevo caso incluyendo la imagen en la base de casos.

En los siguientes apartados se presentan cada una de las fases del ciclo de procesamiento del sistema CBR desarrollado, para finalizar indicando otros aspectos que deben ser tenidos en cuenta.

#### Clasificación por indexación de los casos

En la actualidad se cuenta con alrededor de 800 imágenes, cada una de 1024x768 píxeles y la complejidad de los métodos de cálculo de similitud está alrededor de  $O(\text{ancho} \cdot \text{alto})$  lo que da una idea de lo inviable que resulta comparar cada nueva consulta con todas las imágenes. Para evitar la comparación completa se han indexando los casos, clasificando cada imagen en una serie de clases disjuntas, donde cada clase representa condiciones similares ante un conjunto de atributos en la imagen que hemos considerado característicos por estar relacionados con las diferencias de respuesta en el procesamiento ante distintos métodos. Los atributos que caracterizan las clases son:

- 1) Soleado (valores: *Sí* o *No*)
- 2) Presencia de error en el sembrado (valores: *Sí* o *No*)
- 3) Estado de crecimiento del cultivo (valores: *bajo*, *medio*, *alto*)
- 4) Campo plagado (*Sí* o *No*)

Aunque inicialmente el número de clases posibles es 24 en la práctica, eliminando los casos incoherentes, sólo hay 14 clases. Para cada clase se definen además unas directrices de procesamiento de forma que las imágenes pertenecientes a la misma clase se procesarán de modo similar.

Dada una imagen (ya sea caso o consulta), el sistema calcula el valor para los atributos característicos sin la intervención del usuario. Almacenando los resultados en una base de datos. La indexación de los casos se efectúa previamente a la ejecución del sistema (off-line), y se almacena junto a la demás información del caso. El cálculo de la clase de pertenencia de una imagen, tiene una complejidad de  $O(\text{ancho} \cdot \text{alto})$ .

### Estructura de los casos y de la base de casos

Los casos contienen, además de la imagen en sí, la información usada para la indexación (clase de pertenencia), los métodos a usar en cada etapa y el valor de cada uno de los parámetros de cada uno de los métodos usados. Cuando una imagen no procesada hasta el momento se introduce como consulta, después de haber calculado su clase de pertenencia e independientemente de que luego se almacene también como caso o no, se guarda esta información en la tabla de índices. De esta forma nunca se calculará dos veces la clase de pertenencia de una misma imagen, y se ganará notablemente en eficiencia

Los casos iniciales se etiquetan a mano, usando la plataforma de procesamiento de imágenes que permite al usuario seleccionar los diferentes métodos de procesamiento así como ajustar los valores de los parámetros asociados. Es en esta plataforma en la que se ha integrado el sistema CBR desarrollado. Esta forma de etiquetar los casos, con un usuario experto, suministra situaciones muy cercanas a las óptimas. La tabla 1 resume los resultados de un estudio experimental que indica que métodos y parámetros deben usarse para cada grupo de imágenes. En el caso de la etapa de segmentación se suministran los coeficientes utilizados en la combinación lineal de los tres planos de color RGB para obtener la imagen de escala de grises a partir de la imagen en color. También para este caso se muestra el umbral utilizado para producir la imagen binaria (blanco y negro) a partir de la imagen de escala de grises.

Parámetro	Etapas determinante	Valor	Método y parámetros usados
Soleado	Segmentación	Si	Método S1 RGB(1,2,1) Umbral ~224
		No	Método S1 RGB(0.7 0.588 0.136) Umbral ~247
Error	Eliminación	Si	Método E1 ~75%
		No	Método E2 o E3
Plagado	Todas	Si	Método S1, E3 y F3
		No	Cualquiera
Crecimiento Filtrado		Alto	Método F2
		Medio	Método F3
		Bajo	Método F1

Tabla 1 – Parámetros y métodos para cada clase.

### Recuperación

Una vez indexada la consulta, el sistema debe decidir que caso recuperar, de entre los que pertenecen a su misma clase. Para ello calculamos la similitud entre la imagen de entrada y todas las asociadas a la clase seleccionada, para al final recuperar la imagen más cercana (valor de similitud más alto) a la imagen de entrada. El algoritmo que se utiliza para calcular la similitud entre imágenes fue propuesto en 2004 por Van der Weken [8] y se basa en la distancia de Kullback entre píxeles. El algoritmo es de orden  $O(\text{ancho} \cdot \text{alto})$  y la función de similitud tiene la siguiente expresión:

$$SIM(A, B) = \frac{\sum_{i=0}^n \sum_{j=0}^m |a_{ij} - b_{ij}|}{\sum_{i=0}^n \sum_{j=0}^m (a_{ij} + b_{ij})}$$

Donde  $a_{ij}$  y  $b_{ij}$  representa los valores RGB de los píxeles en la posición  $(i,j)$  de las matrices de píxeles de dimensión  $(n \times m)$  asociadas a las imágenes  $A$  y  $B$  respectivamente.

### Reutilización

La reutilización implementada es sin adaptación por lo que se usan los mismos métodos y valor de los parámetros que el caso recuperado. Para poder adaptar el caso recuperado ajustándolo a la imagen de entrada, el sistema debería tener un conocimiento que por ejemplo le permitiese evaluar los efectos de aumentar el valor de un parámetro en determinadas condiciones. El problema es que este conocimiento es muy intuitivo y de sentido común, y por tanto difícil de codificar.

### Aprendizaje

En la fase de aprendizaje el sistema decide si la consulta procesada debe incluirse a la base de casos o no. Actualmente, el sistema almacena el caso resultado de la consulta sólo si el valor de similitud con el caso recuperado es suficientemente grande (umbral definido por el usuario), de lo contrario no es necesario pues ya existe un ejemplar en la clase que representa las características esenciales de la imagen de entrada. La situación cambiaría si existiese adaptación pues en ese caso habría que almacenar la imagen de entrada con los nuevos parámetros como un nuevo caso.

## 4. RESULTADOS

Para valorar el sistema, se seleccionó de forma aleatoria un conjunto de evaluación de 42 imágenes, de distintos años y distintos campos. Sobre este conjunto de evaluación se estimó los tantos por ciento de mala hierba usando como procesamiento distintas variantes del sistema. Se realizaron pruebas con el sistema sin CBR, con el sistema CBR sólo con la parte de indexación (CBR1), y con el sistema CBR completo. Para la evaluación del sistema sin CBR se probaron dos conjuntos de métodos y parámetros, SinCBR1 y SinCBR2. Para la evaluación del sistema CBR sólo con la parte de indexación (CBR1) se definieron para cada clase el conjunto de métodos y parámetros a aplicar en cada nueva consulta una vez determinada la clase. Para la evaluación del sistema CBR completo se usaron 4 representantes por clase y dos métodos de cálculo de similitud; el que se ha presentado en el apartado tres  $SIM(A,B)$  (CBR2) y una función de similitud basada en la distancia euclídea entre

dos puntos (CBR3). Esto último permite evaluar la dependencia de los resultados del método de cálculo de similitud seleccionado. En la tabla 2 se presentan la descripción de los sistemas evaluados. En los sistemas sin CBR viene detallado el método utilizado en cada etapa y entre paréntesis el valor de los parámetros usados. También se incluye en la tabla los tiempos medios de respuesta de los distintos sistemas.

Sistema	Descripción	Tiempo medio/ imagen
SinCBR1	S1, E2 (35 5), F2(15)	2.16
SinCBR2	S1, E3 (30 40 90), F2(15)	2.25
CBR1	Sólo Indexación	7.14
CBR2	CBR completo con similitud <i>SIM(A,B)</i>	11.63
CBR3	CBR completo con distancia euclídea	10.93

Tabla 2 – Tiempo de respuesta para los distintos sistemas

Puede observarse que el método E3 de eliminación, usado en SinCBR2, provoca un retardo, con respecto al método E2 usado en SinCBR1, de más de 7 segundos por imagen lo que es elevado para las restricciones temporales que existirán si se quiere aplicar el método a una detección de mala hierba en tiempo real con objeto de aplicar el herbicida. Por otro lado, CBR1 tarda menos que los otros dos sistemas CBR algo explicable si se considera que ejecuta ningún cálculo de similitud entre imágenes. También el tiempo de ejecución del sistema CBR1 es inferior al del sistema SinCBR2. Por último, se aprecia que la diferencia de tiempos de ejecución de los sistemas CBR2 y CBR3 es mínima, pero superior, como cabía esperar, a la del resto de sistemas.

En la tabla 3, se muestran los resultados de un estudio de regresión lineal comparando uno a uno todos los sistemas con la biomasa. La biomasa indica la cantidad de materia viva y se calculó para cada punto de muestreo, a partir de una muestra del terreno de la zona central de las fotografías (entre líneas) que fue recogida inmediatamente después de tomar las instantáneas. Por tanto la precisión de los distintos sistemas evaluados se valorará con arreglo al grado de correlación entre la respuesta del sistema (tanto por ciento de mala hierba) y el valor de la biomasa. Se puede apreciar en la figura que los sistemas SinCBR no se ajustan demasiado bien a la biomasa. En cuanto a los sistemas CBR, se ve claramente como los dos sistemas completos (CBR2 y CBR3) presentan mayor exactitud que el resto ajustándose de forma muy satisfactoria a la biomasa y dando valores muy parecidos para todas las imágenes. En contraposición CBR1, debido a que se queda en la parte de clasificación, sin luego ajustarse más a cada tipo de imagen, no logra los resultados de CBR2 y CBR3. También se puede ver que la diferencia entre usar el método de similitud *SIM(A,B)* (CBR2) y el basado en distancia euclídea (CBR3) es mínima.

En la tabla también se incluyen los resultados de la comparación de la evaluación de los expertos, la media de los SinCBR, la media de los CBR con la biomasa. Se comprueba que los

sistemas sin CBR se ajustan peor que el resto a la biomasa. De hecho la comparación en un gráfico de dispersión muestra que la media de las valoraciones de los expertos es siempre bastante superior a la biomasa, incluso llegando a dispararse en ciertas ocasiones, mientras que los sistemas CBR mantienen una distribución más uniforme y ajustada a la biomasa. La disparidad entre la biomasa y la valoración de los expertos se debe a que la estimación del ser humano es bastante subjetiva y tiende a ajustarse a la situación global. Así si un experto empieza con un valor alto de cobertura y se encuentra con una colección de imágenes de un campo muy infestado terminará disminuyendo su estimación en el valor de la cobertura en las últimas imágenes. Se han realizado varios estudios en este sentido, presentando al mismo experto la misma colección de fotos en distintos días y en orden diferente; pudiendo llegar a diferir el valor de la estimación hasta en un 30%. Este hecho justifica la importancia de automatizar el proceso de evaluación del tanto por ciento de malas hierbas, cultivo y suelo presentes en una imagen.

Sistema	Estadístico de Fisher	Sig.	Coefficiente de correlación R
SinCBR1	2.928	.096	.274
SinCBR2	.058	.811	.040
CBR1	2.432	.128	.255
CBR2	18.922	.000	.587
CBR3	15.037	.000	.543
Expertos	8.486	.006	.442
Media SinCBR	4.051	.052	.318
Media CBR	13.712	.001	.525

Tabla 3 - Resultados entre los distintos sistemas y los datos de biomasa

## 5. CONCLUSIONES

En este artículo se ha presentado un sistema novedoso de Razonamiento Basado en Casos que determina automáticamente, la secuencia de métodos de procesamiento, y el valor de los parámetros que requieren los métodos, para dada una fotografía tomada en vertical de una zona de cultivo estimar los tantos por ciento de mala hierba, cultivo y suelo; valores estos fundamentales en la cálculo de la presión de mala hierba parámetro necesario para ajustar la dosis de herbicida y construir los mapas de tratamiento. El sistema CBR desarrollado ha sido probado sobre una base de datos de imágenes tomadas en distintos campos y en distintos años y que por tanto presentaban un amplio rango de situaciones reales diferentes. El sistema ha mostrando ser robusto y flexible ante la naturaleza cambiante de las imágenes y las condiciones en las que estas fueron tomadas. Así pues, se ha conseguido un sistema que se adapta a las distintas características que pueden presentar las imágenes procesadas, dando como resultado valores de

resultando en valores de cobertura de mala hierba muy parecidos a los reales, obtenidos mediante el cálculo de la biomasa.

Después de los distintos estudios y pruebas realizadas, se ha comprobado también que algunos métodos son más rápidos pero menos fiables, mientras que otros son algo lentos pero fiables. También se ha estudiado como influye cada etapa del CBR en los resultados finales, concluyendo que la inclusión de un mejor algoritmo de cálculo de similitud, un mejor ajuste del método de aprendizaje, o la adaptación del caso recuperado mejoraría la precisión del sistema.

## 6. AGRADECIMIENTOS

Los autores queremos agradecer al equipo dirigido por el Dr. Cesar Fernández-Quintanilla el trabajo de campo realizado, las muchas ideas, comentarios y sugerencias que nos han permitido entrar en el campo de la Agricultura de Precisión. También queremos agradecer a todo el personal de la finca experimental de La Poveda y muy especialmente a Pedro Hernaiz su gran ayuda en el trabajo de campo. Este proyecto se financia con fondos de investigación del Ministerio de Educación y Ciencia (AGL2005-06180-C03-03). Xavier P. Burgos-Artizsu disfruta en la actualidad de una beca postgrado del Consejo Superior de Investigaciones Científicas.

## 7. REFERENCIAS

- [1] Cressie, N.A.C: Statistics for spatial data New York: Wiley. (1993)
- [2] Gonzalez R.C. and Woods P.: Digital Image Processing. 2nd Edition. Prentice Hall. (2002)
- [3] Pajares G. and De la Cruz J.M.: Clasificación de texturas naturales mediante k-Means. Revista Electrónica de Visión por Computador 6(3)(2002)1-19
- [4] Ribeiro A. Diaz B., García-Alegre M.C. y Guinea D. A GPS based system to aid in the acquisition of spatially structured field properties. 3ECPA-3rd European Conf on Precision Agriculture. Montpellier. Francia (2001) 97-102
- [5] Ribeiro A., Fernández-Quintanilla C., Barroso J., García-Alegre M.C.: Development of an image analysis system for estimation of weed. Proceeding 5th European Conf. On Precision Agriculture (5ECPA) (2005) 169-174
- [6] Perner P.: Why Case-Based Reasoning Is Attractive for Image Interpretation. In D. Aha and I Watson (Eds.) Case-Based Reasoning Research and Development. Springer-Verlag, LNAI 2080, (2001) 27-44.
- [7] Perner P.: An architecture for a CBR image segmentation system. Engineering Applications of Artificial Intelligence 12(6)(1999)749-759.
- [8] Van der Weken D., Nachtegaal M., Kerre E.E.: Using similarity measures and homogeneity for the comparison of images. Image and Vision Computing 22(2004) pp. 695-702