

Method based in corner and edge detection to separate soybean seedlings structures

Daniel Caio de Lima, Evandro L. L. Rodrigues
Escola de Engenharia de São Carlos – USP
São Carlos, São Paulo, Brasil
daniel.caio@usp.br, evandro@sc.usp.br

Lúcio André de Castro Jorge
Embrapa Instrumentação Agropecuária
São Carlos, São Paulo, Brasil
lucio.jorge@embrapa.br

Abstract—Soybean crops have an important role to Brazilian economy, so it is necessary to establish some methods that can help to assess the quality of this kind of seed. Seed vigor is a value that describes the quality of a seedlot based on the relationship between seed and environment. There is a new computational method to assess the vigor index of a seedlot, but it has some problems with seedlings which hypocotyl is leaning against cotyledon. This paper shows two methods to solve this problem. The first method uses Canny Edge Detector to detect edges in the region where structures are together. The second method is an algorithm that uses SUSAN Corner Detector to find some points to create a line between cotyledon and hypocotyl. The new algorithm shows with 94,35% of correct separation between these structures.

Keywords—seedlings; corner detector; vigor index;

I. INTRODUÇÃO

A cultura de soja desempenha um papel importante na economia brasileira, sendo necessário estabelecer métodos e cuidados para que a qualidade dos grãos não seja prejudicada [1]. Uma das formas mais comuns de se avaliar a qualidade das sementes é através do teste de germinação, definido pelas Regras para Análise de Sementes [2]. Apesar de ser o teste mais comum para avaliar a qualidade, os testes de germinação são considerados incompletos por não levarem em consideração aspectos da relação entre as sementes e o ambiente no qual ela será semeada.

A análise do vigor complementa os resultados dos testes de germinação, dizendo o potencial que um lote de sementes possui para gerar plântulas normais e saudáveis sob um conjunto amplo de condições adversas. Uma das formas mais simples para avaliar o vigor de sementes é a mensuração de estruturas das plântulas que são, em plântulas de soja, o hipocótilo e a raiz primária (Figura 1)

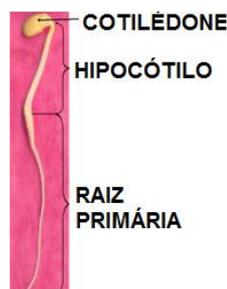


Figura 1 – Estruturas da plântula de soja [1]

Métodos computacionais foram desenvolvidos de modo a automatizar a avaliação do vigor de sementes em diferentes espécies, sendo estes descritos em [3], [4], [5] e [6]. Em [1], foi proposta uma nova abordagem para avaliação do vigor de sementes de soja, sendo que os resultados se mostraram satisfatórios para a resolução do problema em questão, porém, alguns problemas ainda prejudicaram o desempenho do método, como plântulas nas quais o hipocótilo/raiz nasceu encostado no cotilédono, prejudicando assim na remoção do cotilédono e excluindo parte do hipocótilo, tornando impossível medir a raiz por completo.

Nesse trabalho serão apresentadas técnicas para separar os cotilédones das raízes quando estes estão juntos, de modo a resolver o problema encontrado em [1], melhorando assim os resultados do cálculo do índice de vigor.

Na seção II serão apresentadas de modo breve as técnicas básicas utilizadas neste trabalho. Na seção III são mostradas as etapas e procedimentos para a construção dos métodos propostos. Na seção IV serão mostrados os resultados para cada método desenvolvido. Finalmente, na seção V será mostrada a conclusão baseada nos resultados obtidos.

II. FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão descritas, de modo sucinto, algumas técnicas utilizadas para elaboração do método descrito na seção 3 e para atingir os resultados.

A. Harris Corner Detector

O detector de Harris [7] é o detector de cantos mais utilizado na literatura, sendo que a técnica é uma melhoria do detector de Moravec [8], se diferenciando do mesmo pelo fato de considerar deslocamentos de uma pequena janela centrada em um ponto da imagem em qualquer direção, enquanto o detector Moravec considera deslocamentos apenas em ângulos de 45°. Outra característica que diferencia as técnicas é a utilização de uma janela gaussiana circular para redução dos ruídos presentes na imagem.

O detector de Harris é baseado na função de auto-correlação local que mede as variações locais do sinal com correções nos deslocamentos. Considerando-se um deslocamento (x,y) e um ponto, a função de auto-correlação local é dada pela equação 1 [8]:

$$c(x, y) = \sum_w [I(x_i, y_i) - I(x_i + \Delta x, y_i + \Delta y)]^2 \quad (1)$$

Na equação 1 tem-se $I(x_i, y_i)$ como sendo a função da imagem e (x_i, y_i) como sendo os pontos na janela W com centro em (x, y) . Através da aproximação pela expansão de Taylor, tem-se a seguinte equação (2) para representar a imagem deslocada:

$$I(x_i + \Delta x, y_i + \Delta y) \approx [I(x_i, y_i) + [I_x(x_i, y_i)]] \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \quad (2)$$

Na equação 2 temos $I_x(x_i, y_i)$ e $I_y(x_i, y_i)$ como sendo derivadas parciais em x e y , respectivamente. Ao substituir-se a equação 2 na equação 1 e ao considerar-se filtros do tipo $[-1, 0, 1]$ e $[-1, 0, 1]^T$, as derivadas parciais podem ser calculadas, gerando a equação 3.

$$c(x, y) = [\Delta x \quad \Delta y] C(x, y) \begin{bmatrix} \Delta x \\ \Delta y \end{bmatrix} \quad (3)$$

$C(x, y)$ é a matriz de auto-correção que captura a estrutura de intensidade na vizinhança local, apresentada em 4:

$$C(x, y) = \begin{bmatrix} \sum_w (I_x(x_i, y_i))^2 & \sum_w I_x(x_i, y_i) I_y(x_i, y_i) \\ \sum_w I_x(x_i, y_i) I_y(x_i, y_i) & \sum_w (I_y(x_i, y_i))^2 \end{bmatrix} \quad (4)$$

B. SUSAN Corner Detector

A técnica *Smallest Segment Assimilating Nucleus* (SUSAN) [9] consiste em utilizar uma máscara circular que é comparada a cada *pixel* da imagem, verificando o brilho dos mesmos. Se os *pixels* que estiverem sob a máscara possuírem brilho semelhante ao brilho do *pixel* que está no núcleo da máscara, então, essa área da máscara pode ser considerada com o mesmo brilho do núcleo, sendo chamada de USAN (*Univalue Segment Assimilating Nucleus*). A Figura 2 mostra um exemplo no qual quatro máscaras circulares estão em diferentes posições em um retângulo com uma cor destacada em relação ao plano de fundo.

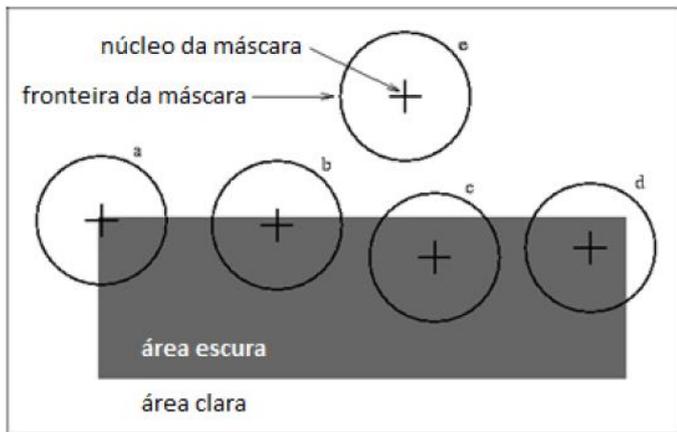


Figura 2 – Quatro máscaras circulares em diferentes posições de um retângulo [9].

A detecção dos cantos ocorre de acordo com a área do USAN, exatamente quando a máscara se encontra em posição semelhante à posição *a* da Figura 1, posição em que a área dentro da máscara é mínima.

A equação 5 mostra a comparação de similaridade entre os *pixels* da imagem presentes dentro da máscara e o do núcleo:

$$c(r, r_0) = \exp \left\{ - \left[\frac{I(r) - I(r_0)}{t} \right]^6 \right\} \quad (5)$$

Na equação anterior (5), r_0 é o par de coordenadas do núcleo da máscara, r são as coordenadas dos outros pontos da imagem presentes dentro da máscara, $C(r_0, r)$ é o resultado da comparação entre os *pixels*, $I(r)$ e $I(r_0)$ são, respectivamente, valores de níveis de cinza para os pontos da imagem e o ponto do núcleo. A variável t representa o valor limiar entre a diferença dos níveis de cinza que determina a capacidade do método ser tolerante a ruídos e o menor valor para o contraste que pode ser identificado pelo detector.

III. METODOLOGIA

As etapas desse trabalho foram desenvolvidas na linguagem de programação C#, utilizando as bibliotecas de visão computacional *EMGU CV* e *Aforge.net*.

A. Seleção das imagens de plântulas

As imagens das plântulas germinadas foram fornecidas pelo Departamento de Produção Vegetal da Escola Superior de Agricultura “Luiz de Queiróz” (USP-ESALQ), sendo enviadas 119 imagens capturadas por *scanner*, contendo 20 plântulas de soja, sendo um total de 2380 plântulas. Do total de imagens, foram selecionadas 425 plântulas nas quais a raiz surgiu encostada no cotilédone em diferentes posições. Alguns exemplos de plântulas encontradas nessa situação são mostradas na Figura 3.



Figura 3 – Plântulas de soja com junção entre hipocótilo/raiz e cotilédone.

B. Método detector de bordas Canny

Em cada uma das imagens das plântulas foi utilizado o detector de bordas Canny com o objetivo de extração dos contornos das plântulas, de modo a abrir espaço entre os cotilédones e as raízes. Foram utilizados valores de *threshold* até 20 para realizar a detecção de bordas, sendo um exemplo de borda detectado a Figura 4.



Figura 4 – Fronteiras detectadas pelo detector Canny.

No exemplo da Figura 4 é possível observar que foi detectado um contorno no local em que as duas partes da plântula estavam juntas. Para abrir o espaço nas imagens binárias das plântulas foi realizada uma operação lógica ou-exclusivo (XOR) entre essas e imagens e seus respectivos contornos, deixando a imagem binária da plântula com uma abertura na região.

C. Método com detector de cantos

Foi desenvolvido um algoritmo que utiliza métodos de detecção de cantos para detectar pontos na imagem binária nas regiões formadas entre o cotilédone e hipocótilo. Na Figura 5, temos exemplos dessas regiões destacadas em vermelho.



Figura 5 – Regiões para detecção de pontos.

Foram testados dois detectores para extrair esses pontos na imagem, os detectores de Harris e SUSAN. Testes preliminares foram realizados de modo a verificar qual detector se adaptaria melhor à detecção dos pontos nas regiões de interesse. Os resultados preliminares mostraram que o detector de Harris retornou uma quantidade excessiva de pontos, principalmente em regiões externas da plântula, tornando mais complexo o desenvolvimento de um algoritmo. A Figura 6 mostra exemplos dos resultados preliminares para os detectores de Harris e SUSAN, respectivamente, com os pontos detectados destacados em vermelho.

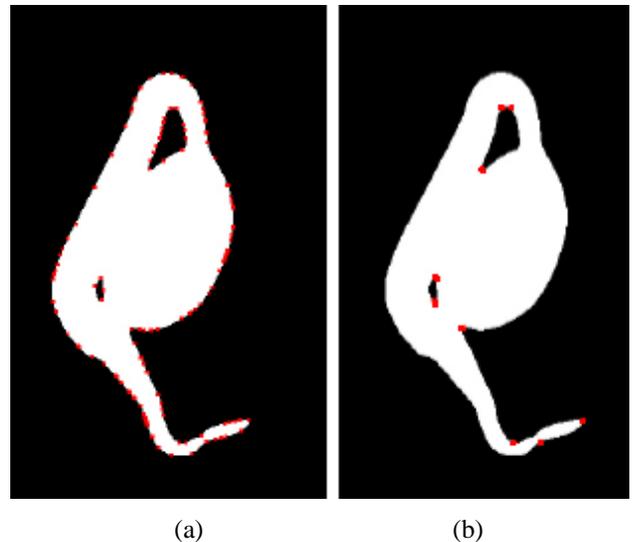


Figura 6 – Cantos detectados. (a) Harris e (b) SUSAN.

Como pôde ser observado, o detector SUSAN capta uma menor quantidade de pontos, sendo que alguns deles estão dentro da região de interesse e outros fora dessa região. O algoritmo deve excluir esses pontos do conjunto de pontos úteis para a construção de retas que serão traçadas para abrir espaço nessas regiões.

O primeiro passo do algoritmo desenvolvido é detectar a presença de “buracos” na imagem binária da plântula, sendo a presença destes uma condição para execução do algoritmo. A detecção dos “buracos” é feita considerando-se os *pixels* do *background* como pertencentes a objetos. O algoritmo SUSAN é aplicado em cada imagem binária e cada um dos pontos de *corner* é armazenado em uma lista, assim como os pontos de cada “buraco” (região de interesse) são armazenados em outra lista. As duas listas são comparadas dentro de um *loop*, verificando se um ponto da lista global de pontos é igual a um ponto da lista da região de interesse, esse ponto é armazenado em uma outra lista contendo os pontos utilizados para “cortar” a imagem, excluindo os pontos localizados fora da região de interesse. A Figura 7 mostra um exemplo de pontos externo de interesse para criação da reta que abrirá o espaço entre as estruturas.

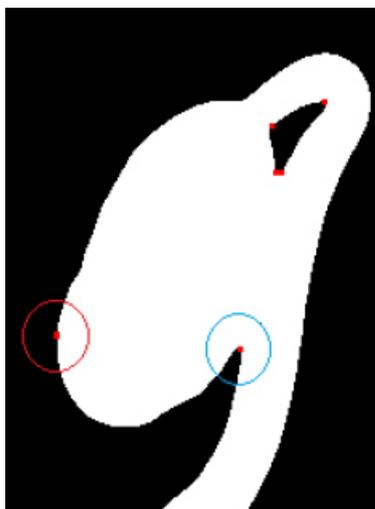


Figura 7 – Ponto externo fora da região de interesse (círculo vermelho) e ponto externo de interesse (círculo azul).

Para que o ponto externo de interesse pudesse ser encontrado, foi utilizada a localização do último ponto encontrado dentro da região interna da plântula binária. A partir da análise do conjunto de imagens selecionadas foi possível identificar um padrão nas plântulas que germinaram com o hipocótilo encostado no cotilédone, sendo esta a localização do ponto externo útil para a construção da reta. Esse ponto se localiza abaixo (coordenada Y) do último “buraco” da imagem binária, sendo o ponto de menor distância no eixo X em relação ao último buraco localizado dentro da última região interna detectada pelo algoritmo. A distância no eixo X tem maior importância em relação à distância no eixo Y. A Figura 8 exemplifica a situação da prioridade da distância no eixo X sob a distância no eixo Y, na qual o primeiro ponto externo localizado é o mais próximo ao se observar a distância no eixo Y, porém é o mais distante no eixo X, sendo um ponto a ser descartado para a criação da reta de separação.

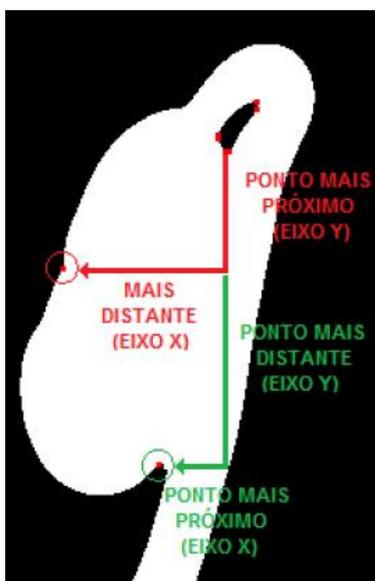


Figura 8 – Comparação entre distâncias entre pontos externos e a região do “buraco”

Depois de selecionado, o ponto externo é adicionado à lista de pontos para criação de retas e estas são criadas, sendo estas criadas de acordo com o número de regiões internas. A Figura 9 mostra um exemplo no qual apenas uma reta foi criada para separar as duas estruturas e Figura 10 mostra um exemplo no qual a plântula possui duas regiões internas, sendo criadas duas retas.

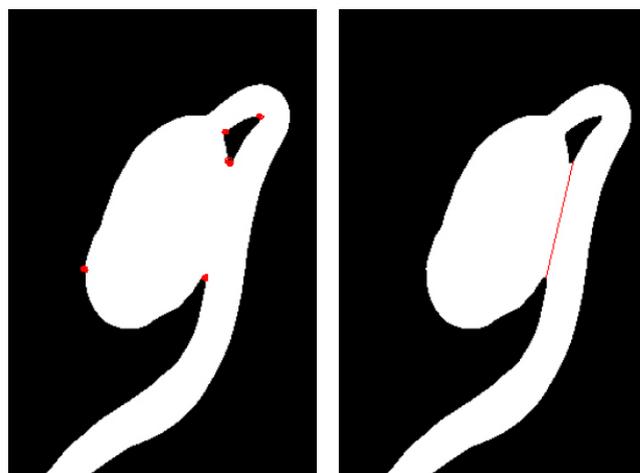


Figura 9 – Pontos detectados (esquerda) e reta traçada (direita)

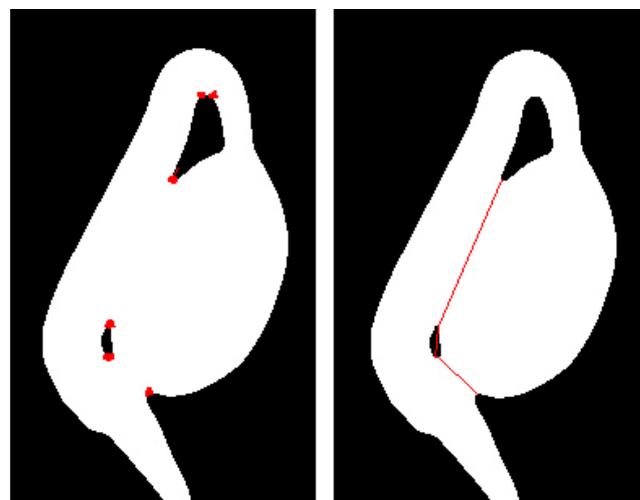


Figura 10 – Pontos detectados (esquerda) e reta traçada (direita).

IV. RESULTADOS

Foram realizados testes utilizando o detector de Canny e o algoritmo desenvolvido para separar as duas partes da plântula. As 425 imagens selecionadas foram submetidas aos dois métodos de separação, sendo que cada imagem resultante do processo foi avaliada visualmente, verificando se o cotilédone foi separado do hipocótilo corretamente. Na Figura 11 são mostrados exemplos de plântulas com separação correta para os dois métodos propostos.

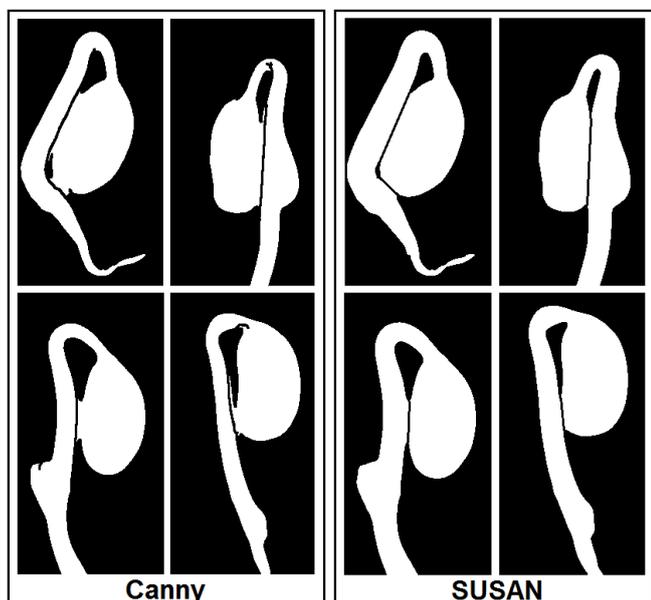


Figura 11 – Acertos para os dois métodos.

Na Figura 12 são mostrados exemplos de plântulas que tiveram a separação entre o cotilédone e o hipocótilo de forma incorreta.

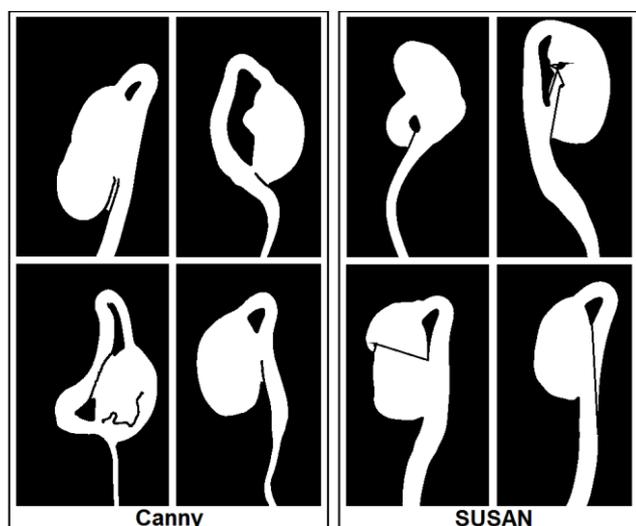


Figura 12 – Erros para os dois métodos.

Ao fim da análise visual, constatou se que o método de separação que utiliza o detector Canny apresentou 64,94% de plântulas com o cotilédone corretamente separado do hipocótilo, sendo um desempenho considerado um resultado ruim por especialistas de análise de sementes, além de gerar defeitos nas imagens binárias, defeitos estes que podem ocasionar em várias ramificações após a realização do afinamento, útil no processo automatizado para análise automatizada do vigor de sementes [1]. O método que utiliza o detector de SUSAN apresentou 94,35% de plântulas com a separação feita corretamente, sendo a melhor opção encontrada para separar corretamente as duas partes da plântula.

O algoritmo desenvolvido foi testado nas imagens dos 120 lotes de sementes, divididas de acordo com a coloração do

papel de germinação. 59 lotes tiveram a imagem capturada em papel cor-de-rosa e 60 lotes tiveram imagens capturadas com coloração azul, sendo que 88,47% das plântulas tiveram seu cotilédone corretamente separado do hipocótilo/raiz nas imagens com papel cor-de-rosa, tonando possível identificar e medir toda a extensão da raiz primária das plântulas. Nos testes com o papel azul, o percentual de plântulas corretamente separadas das raízes aumentou para 91%. A Tabela 1 mostra o resultado do teste T de Student comparando os resultados para os dois tipos de cor de papel de germinação.

TABELA 1 TESTE-T: DUAS AMOSTRAS PRESUMINDO VARIANCIAS DIFERENTES

	Lotes em papel cor-de-rosa	Lotes em papel azul
Média	0,884694915	0,91004
Variância	0,006136009	0,003376232
Observações	59	60
Hipótese da diferença de média	0	
gl	107	
Stat t	-2,002012176	
P(T<=t) uni-caudal	0,023906864	
t crítico uni-caudal	1,659219312	
P(T<=t) bi-caudal	0,047813728	
t crítico bi-caudal	1,98238337	

O valor-p calculado pelo teste T de Student foi de 4,78%, assim rejeitando a hipótese da cor do papel de germinação ser irrelevante para um bom funcionamento da técnica, mostrando que o uso do papel azul de fato apresenta melhores resultados.

V. CONCLUSÕES

A partir da análise dos resultados obtidos pelos dois métodos testados para separar cotilédone de hipocótilo é possível concluir que o método de separação que utiliza a detecção de *corners* SUSAN obteve resultado superior ao método de separação que utiliza a detecção de bordas, com 94,35% de plântulas que tiveram o cotilédone corretamente separado do hipocótilo, permitindo assim que uma melhor mensuração das plântulas para o cálculo automático do índice de vigor do lote de sementes.

Outro ponto a ser destacado é que o algoritmo teve um melhor desempenho nos casos em que as imagens das plântulas estavam no papel de cor azul, sendo que o percentual de plântulas com separação correta foi de 91%, enquanto o acerto para o papel cor-de-rosa foi de 88,47%.

AGRADECIMENTOS

Agradecemos ao apoio financeiro do projeto CNPq 403426/2013-8.

REFERÊNCIAS

- [1] D.C. de Lima, E.L.L. Rodrigues, e L.A.C. Jorge, “A new approach to automate the seed vigor analysis on soybean seedling using digital images”, X Workshop de Visão Computacional, p. 157-161, 2014.
- [2] BRASIL, Ministério da Agricultura, Pecuária e Abastecimento, “Regras para Análise de Sementes”, Brasília, 2009. 395p.
- [3] A. C. McCormac, P. D. Keefe and S. R. Draper, “Automated Vigour Testing of Field Vegetables Using Image Analysis”, SeedSci. & Technol, p.103-112. 1990.

- [4] M. S. Howarth and P. C. Stanwood, "Measurement of Seedling Growth Rate by Machine Vision", Transactions of American Society of Agricultural Engineering, v.36,n.3,1993, p.959-963.
- [5] Y. Sako, M. B. McDonald, K. Fujimura, A. F. Evans and M. A. Bennett, "A system for automated vigor assessment", Ohio State University, 2001. M. Young, The Technical Writer's Handbook. Mill Valley, CA: University Science, 1989.
- [6] A. L. Hoffmaster, M. B. Fujimura, M. B. McDonald and M. A. Bennett, "An Automated System for Vigor Testing Three-Day-Old Soybean Seedlings", The Ohio State University, 2003.
- [7] C. Harris, M. Stephens, 'A combined corner and edge detector', 4th Alvey Vision Conference, p. 147-151, 1988.
- [8] N. Dey, P. Nandi, N. Barman, D. Das, S. Chakraborty, "A comparative study between Moravec and Harris Corner Detection of noisy images using adaptative Wavelet thresholding technique", International Journal of Engineering Research and Applications, v.2, p. 599-606, 2012.
- [9] S.M. Smith, J.M. Brady, "SUSAN – A new approach to low level image processing", International Journal of Computer Vision, vol. 23, p.45-78, 1997.