

Detecció i extracció d'avions a seqüències de vídeo

Marc Garcia i Ramis

Directors :

Sergio Escalera Guerrero

Carlos Gallardo García

Alberto Escudero Pardo

Motivació

- AENA. Els aeroports cada dia estan més concorreguts.
- Plantejament d'un problema real. I resolució amb ús de noves tecnologies.
- Amb la nostra aplicació tractem de facilitar les tasques als operaris.




Objectiu

- General



- Concret



Índex

- 1 - Contextualització del problema
- 2 - Metodologia
- 3 - Resultats
- 4 - Conclusions
- 5 - Demostració pràctica

Contextualització del problema



- Fins al moment, els operaris controlaven l'arribada de gran quantitat d'avions alhora.



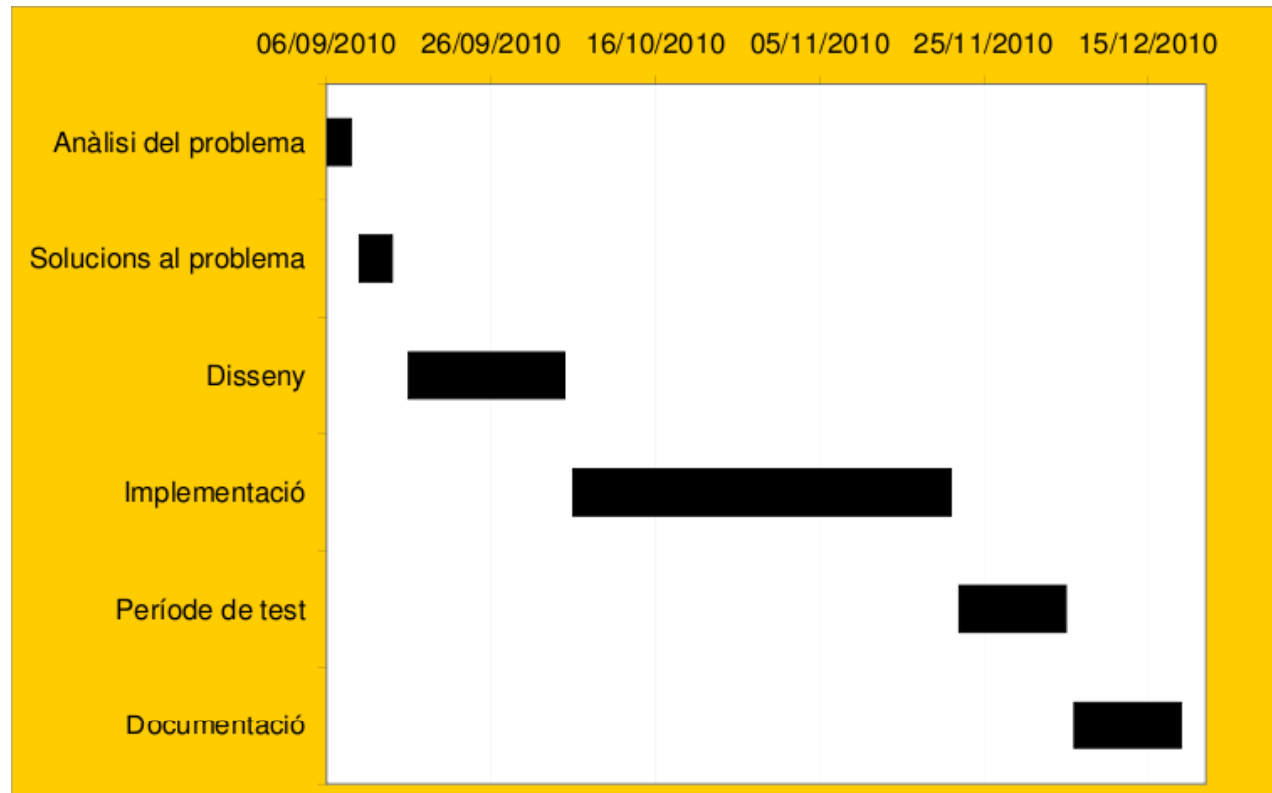
Contextualització del problema

- El nostre projecte facilitarà la tasca dels operaris. Donarà més autonomia als avions per aparcar.



Contextualització del problema

- Planificació per la resolució dels objectius.



Índex

- 1 - Contextualització del problema
- 2 - Metodologia
- 3 - Resultats
- 4 - Conclusions
- 5 - Demostració pràctica



Metodologia

Abans de començar la part tècnica...

- Qué significa fer una Background subtraction?
- Quines passes haurem de seguir?
 - Lectura de l'entrada
 - Aplicar mètode
 - Etapa de morfologia
 - Comparació resultats

Metodologia

Diferents mètodes que podem seleccionar:

- Eigen Background subtraction

- N imatges. $[I_t]_{t=1,2,\dots,N}$

- Mitjana del fons. $X_t = I_t - \mu_b$

- Matriu diagonal. $L_b = \Phi_b C_b \Phi_b^T$

- Per cada imatge nova comprovam.

$$I_t^B = \Phi_{Mb}(I_t - \mu_b) \rightarrow D_t = |I_t - I_t^B| > \theta$$

Metodologia

Diferents mètodes que podem seleccionar:

- Mean

- N frames (inici). $[I_t]_{t=1,2,\dots,N}$

- Model de probabilitat de densitat.

$$r = R/(R + G + B) \quad g = G/(R + G + B)$$

- Per cada nova entrada:

$$\begin{aligned} \mu_{i,t} &= (1 - \alpha)\mu_{i,t-1} + \alpha(I_{i,t}) \\ \sigma_{i,t}^2 &= (1 - \alpha)\sigma_{i,t-1}^2 + \alpha(I_{i,t} - \mu_{i,t})^T (I_{i,t} - \mu_{i,t}) \end{aligned}$$

Metodologia

Diferents mètodes que podem seleccionar:

- Adaptive

- Per compensar ambdós mètodes :

$$D_i(B) = \lambda D_i(E) + (1 - \lambda)$$

$$D_i(G)D_i(E) = |I_i - B_i|$$

$$D_i(G) = \left(\frac{(I_{r,i} - \mu_r)^2}{\sigma_r^2} + \frac{(I_{g,i} - \mu_g)^2}{\sigma_g^2} \right)$$

$$\lambda = 1 - \exp(-(I_i - \mu_i)^2 / \eta^2)$$

Metodologia

Diferents mètodes que podem seleccionar:

- Grimson

- Valors històrics per cada píxel i modelació amb distribucions gaussianes.

$$\{X_1, \dots, X_t\} = \{I(x_0, y_0, i) : 1 \leq i \leq t\}$$

- Valors històrics per cada píxel.

$$P(X_t) = \sum_{i=1}^K \omega_{i,t} * \eta(X_t, \mu_{i,t}, \Sigma_{i,t})$$

- Probabilitat de densitat.

$$\eta(X_t, \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} e^{-\frac{1}{2}(X_t - \mu)^T \Sigma^{-1} (X_t - \mu)}$$

Metodologia

- Assumim matriu de covariància com:

$$\Sigma_{k,t} = \sigma_k^2 \mathbf{I}$$

- Pes de les K distribucions en moment t.

$$\omega_{k,t} = (1 - \alpha)\omega_{k,t-1} + \alpha(M_{k,t})$$

- Fórmules per modulació.

$$\mu_t = (1 - \rho)\mu_{t-1} + \rho X_t$$

$$\sigma_t^2 = (1 - \rho)\sigma_{t-1}^2 + \rho(X_t - \mu_t)^T (X_t - \mu_t)$$

tal que:

$$\rho = \alpha \eta(X_t | \mu_k, \sigma_k)$$

Metodologia

Diferents mètodes que podem seleccionar:

- Wren
 - Modelació de l'objecte

$$\Pr(\mathbf{O}) = \frac{\exp\left[-\frac{1}{2}(\mathbf{O} - \boldsymbol{\mu})^T \mathbf{K}^{-1}(\mathbf{O} - \boldsymbol{\mu})\right]}{(2\pi)^{\frac{m}{2}} |\mathbf{K}|^{\frac{1}{2}}}$$

$$s_k(x, y) = \begin{cases} 1 & (x, y) \in k \\ 0 & \text{otherwise} \end{cases}$$

- Modelació de l'escena.

$$\boldsymbol{\mu}_t = \alpha \mathbf{y} + (1 - \alpha) \boldsymbol{\mu}_{t-1}$$

Metodologia

- Modelació del moviment.

$$\hat{\mathbf{X}}_{[n|n]} = \hat{\mathbf{X}}_{[n|n-1]} + \hat{\mathbf{G}}_{[n]} \left\{ \hat{\mathbf{Y}}_{[n]} - \hat{\mathbf{X}}_{[n|n-1]} \right\}$$

$$d_k = -\frac{1}{2} (\mathbf{y}^* - \boldsymbol{\mu}_k^*)^T \mathbf{K}_k^{*-1} (\mathbf{y}^* - \boldsymbol{\mu}_k^*) - \frac{1}{2} \ln |\mathbf{K}_k^*| - \frac{m}{2} \ln(2\pi)$$

$$\hat{\boldsymbol{\mu}}_k = E \left[(\mathbf{y} - \boldsymbol{\mu}_k) (\mathbf{y} - \boldsymbol{\mu}_k)^T \right]$$

$$\hat{\mathbf{K}}_k = E \left[(\mathbf{y} - \boldsymbol{\mu}_k) (\mathbf{y} - \boldsymbol{\mu}_k)^T \right]$$

Metodologia

Diferents mètodes que podem seleccionar:

- Prati

- Objecte a conèixer en un moment t:

$$\mathbf{KO}^t = \{\mathbf{MVO}^t\} \cup \{\mathbf{MVO}_{SH}^t\} \cup \{\mathbf{G}^t\} \cup \{\mathbf{G}_{SH}^t\}$$

- A partir d 'informació (del grup S), avaluem el punt p.

$$S = \{\mathbf{I}^t(p), \mathbf{I}^{t-\Delta t}(p), \dots, \mathbf{I}^{t-n\Delta t}(p)\} \cup w_b\{\mathbf{B}^t(p)\}$$



$$\mathbf{B}_s^{t+\Delta t}(p) = \arg \min_{i=1, \dots, k} \sum_{j=1}^k \text{Distance}(\mathbf{x}_i, \mathbf{x}_j) \quad \mathbf{x}_i, \mathbf{x}_j \in S,$$

Metodologia

- L'aprenentatge del background:

$$\mathbf{B}_k^{t+\Delta t}(p) = \begin{cases} \mathbf{B}^t(p) & \text{if } p \in \mathbf{O}, \mathbf{O} \text{ in } \{\mathbf{MVO}^t\} \cup \{\mathbf{MVO}_{\text{SH}}^t\} \\ \mathbf{B}_s^{t+\Delta t}(p) & \text{if } p \in \mathbf{O}, \mathbf{O} \text{ in } \{\mathbf{G}^t\} \cup \{\mathbf{G}_{\text{SH}}^t\}. \end{cases}$$

- A cada punt l'avaluarem segons:

$$\mathbf{B}^{t+\Delta t}(p) = \begin{cases} \mathbf{B}_s^{t+\Delta t}(p) & \text{if } \nexists \mathbf{O} \in \mathbf{KO}^t : p \in \mathbf{O} \\ \mathbf{B}_k^{t+\Delta t}(p) & \text{otherwise.} \end{cases}$$

- Per millorar la detecció considerem:

$$\mathbf{DB}^t(p) = \text{Distance}(\mathbf{I}^t(p), \mathbf{B}^t(p))$$

Metodologia

Diferents mètodes que podem seleccionar:

- Zivkovic

- Avaluarem els píxels segons:

$$\frac{p(\mathbf{BG}|\vec{x}^{(t)})}{p(\mathbf{FG}|\vec{x}^{(t)})} = \frac{p(\vec{x}^{(t)}|\mathbf{BG})p(\mathbf{BG})}{p(\vec{x}^{(t)}|\mathbf{FG})p(\mathbf{FG})} \begin{cases} \text{si } > 1 \text{ fons (BG - background)} \\ \text{si } < 1 \text{ objecte (FG - foreground)} \end{cases}$$

-Per calcular el fons.

$$p(\vec{x}^{(t)}|\mathbf{BG}) > c_{\text{thr}} (= p(\vec{x}^{(t)}|\mathbf{FG})p(\mathbf{FG})/p(\mathbf{BG}))$$

-Per adaptar els canvis.

$$\hat{p}(\vec{x}|\mathcal{X}_T, \mathbf{BG} + \mathbf{FG}) = \sum_{m=1}^M \hat{\pi}_m \mathcal{N}(\vec{x}; \hat{\mu}_m, \hat{\sigma}_m^2 I)$$

Metodologia

- Per una nova entrada

$$\hat{\pi}_m \leftarrow \hat{\pi}_m + \alpha(o_m^{(t)} - \hat{\pi}_m),$$

$$\hat{\mu}_m \leftarrow \hat{\mu}_m + o_m^{(t)}(\alpha/\hat{\pi}_m)\vec{\delta}_m,$$

$$\hat{\sigma}_m^2 \leftarrow \hat{\sigma}_m^2 + o_m^{(t)}(\alpha/\hat{\pi}_m)(\vec{\delta}_m^T \vec{\delta}_m - \hat{\sigma}_m^2)$$

$$\vec{\delta}_m = \vec{x}^{(t)} - \hat{\mu}_m$$

- Calcularem la distància Mahalanobis:


$$D_m^2(\vec{x}^{(t)}) = \vec{\delta}_m^T \vec{\delta}_m / \hat{\sigma}_m^2$$

- Nou component.

$$\hat{\pi}_{M+1} = \alpha \quad \hat{\mu}_{M+1} = \vec{x}^{(t)} \quad \hat{\sigma}_{M+1} = \sigma_0$$


Metodologia

- A continuació, haurem d'aplicar l'etapa morfològica.



Metodologia

- Per acabar amb l'apartat parlarem de la comparació de resultats.



Índex

- 1 - Contextualització del problema
- 2 - Metodologia
- 3 - Resultats
- 4 - Conclusions
- 5 - Demostració pràctica

Resultats

- Divisió, detalls i característiques de cada estudi.
 - Dia, vespre/matinada, i nit.
 - El número de frame que estudiem serà diferent per cada vídeo.
 - Dos paràmetres a avaluar : temps i efectivitat.
 - Diferents models d'avió.

Resultats

- Taules estadístiques.
 - Avaluació sobre temps i efectivitat.

	Diurn			Nocturn			Vespre	
	A320	B757	CRJ200	B717	B737	E145	B767	DH8
Eigen	X	X	X	1m15s	59s	X	X	49s
Wren	46s	2m1s	55s	X	49s	4m5s	2m27s	X
Adaptive	51s	2m14s	26s	53s	23s	51s	32s	37s
Grimson	1m20s	5m11s	1m22s	X	X	6m20s	5m03s	X
Zivkovic	52s	2m30s	49s	1m2s	X	1m15s	2m9s	X
Prati	1m48s	4m10s	1m50s	2m21s	1m33s	4m25s	5m	1m15m
Mean	54s	2m26s	1m2s	1m13s	59s	3m12s	2m46s	41s

- Avaluació de percentatges

	Diurn - CRJ200	Nocturn - B717	Vespre - 767
Wren	24'2%		
Zivkovic	21'5%	16'3%	61'3%
Adaptive		14'8%	59'38%
Total	34'9%	22%	68'8%

Resultats

- Mètode per mètode.
 - Eigen : 37'5% efectivitat. Bons resultats de nit.
 - Mean : 100% efectivitat. Però poca precisió.
 - Adaptive : 100% efectivitat. Baix temps de còmput i precisió.
 - Grimson : 62'5% efectivitat. Alt temps d'execució però excel·lents resultats.
 - Wren : 75% efectivitat. Temps competitiu i alta precisió de dia.
 - Prati : 100% efectivitat. Precisió nul·la o molt baixa.
 - Zivkovic : 75% efectivitat. Baix temps de còmput i resultats detallats.

Índex

- 1 - Contextualització del problema
- 2 - Metodologia
- 3 - Resultats
- 4 - Conclusions
- 5 - Demostració pràctica



Conclusions

- Perfilar els mètodes de manera més específica.
- Eliminar els mètodes amb pitjors resultats.
- Combinar tots els resultats dels mètodes seleccionats. Leave one out.
- Optimitzar variables per reduir al màxim temps de còmput per poder executar a temps real.

Índex

- 1 - Contextualització del problema
- 2 - Metodologia
- 3 - Resultats
- 4 - Conclusions
- 5 - Demostració pràctica