

國立臺灣大學工學院工程科學及海洋工程學系



碩士論文

Department of Engineering Science and Ocean Engineering

College of Engineering

National Taiwan University

Master Thesis

工地安全監控系統

A Construction Site Surveillance System

陳韋成

Wei-Cheng Chen

指導教授：丁肇隆 博士

張瑞益 博士

Advisor : Chao-Lung Ting, Ph.D.

Ray-I Chang, Ph.D.

中華民國 104 年 06 月

June, 2015

口試委員會審定書



國立臺灣大學碩士學位論文

口試委員會審定書

工地安全監控系統

A Construction Site Surveillance System

本論文係陳韋成君（R02525064）在國立臺灣大學工程科學及海洋工程學系完成之碩士學位論文，於民國 104 年 06 月 12 日承下列考試委員審查通過及口試及格，特此證明

口試委員：丁肇隆 張裕益 (指導教授)

呂承諭

張信良

系主任 黃雅信

致謝



時光匆匆，轉眼兩年間的碩士生涯即將結束，首先要感謝指導教授丁肇隆博士、張瑞益博士，在研究所求學過程給予很多的幫助，無論是事物的學習、研究的方法，對於我的研究，總是不厭其煩地給予許多建議及教誨，使我獲益良多，在此對兩位老師獻上最誠摯的謝意。另外還要感謝口試委員呂承諭博士、張信宏博士對於論文的指導與建議，使得論文更加完善。

感謝實驗室許多成員的照顧與陪伴。謝謝博士班學長忠原、育賢，帶領著我進入影像處理領域，陪我討論、給予我意見，總是能使我收穫許多。在此也特別感謝忠原學長，為了陪我解決問題，一起在實驗室熬了無數個夜晚。謝謝學長姐億鑫、勤昇、宇翔、哲論、玟君這兩年的照顧與鼓勵；感謝同學雯方、威言、瑞華、佳柔、千雅、宏達、竹君，一起修課、在研究上互相學習，共同經歷許多挑戰；學弟妹建晴、宣儀、乃藩、郁琪、忠毅、加容、佳儒，謝謝你們用心的為實驗室籌辦著活動，為大家帶來許多歡樂時光。謝謝冠綸、宥勝、正淵、證膜，碩士兩年有你們的相伴，使得生活更加多彩。

感謝我親愛的家人，給予我支持與鼓勵，使我能專心在研究上，順利的完成碩士學位，謝謝你們。最後，謹以此篇論文獻給所有關心我的人。

陳韋成 謹致於

國立台灣大學 工程科學及海洋工程學系 資訊與網路實驗室(Lab 125a)

中華民國 104 年 6 月

摘要




近年來工地事故頻傳，營造業之重大職業災害發生比率，相較於其他行業更為嚴重。其中，工地人員裝備安全配戴不齊為造成嚴重傷害的主要原因。為了避免悲劇一再發生，藉由人體偵測及物件辨識技術，判定勞工進入工地時是否按規定著裝，以達到更全面性的安全檢查。

本論文主要分為三大部分：影像前處理、特徵擷取及辨識。首先，以網路攝影機拍攝影像後，透過背景相減法擷取移動的前景影像，藉由前景高度動態定位出頭部及軀幹位置，接著再各別抽取色調直方圖、飽和直方圖以及區域二元圖樣(Local Binary Pattern, LBP)作為特徵，再交由支持向量機(Support Vector Machine, SVM)進行分類。實驗結果顯示，本系統可以有效的辨識工地安全帽及工地背心，其準確率分別為97%和93%。

關鍵字： 服裝辨識、安全帽偵測、背心偵測、人體比例分析

ABSTRACT



Numerous construction site accidents have happened around the world in recently years. According to the Ministry of Labor, the occurrence rate of severe occupational injury in construction industry is much higher than others. This high risk is primarily caused by the deficiency of the personal protective equipment (PPE). In this thesis, we apply to the technique of body detection and object recognition on PPE checking system to examine whether construction workers are equipped as prescribed or not. As the result, the rate of construction hazard could be reduced.

There are three parts in our system which including image preprocessing, feature extraction and recognition. First, videos of workers are taken by an IP camera. Then, the moving foreground images would be extracted by background subtraction, and the positions of head and body are located by the height of the foreground image. Lastly, the Support vector machine (SVM) is utilized to perform classification on the features which are hue histogram, saturation histogram and local binary pattern (LBP). The experiment results show the system could effectively recognize the safety hats and safety vests with the accuracies of 97% and 93%, respectively.

Keywords: *clothing recognition, hard hat detection, vest detection, torso proportions analysis*

論文目錄



口試委員會審定書	i
致謝	ii
摘要	iii
ABSTRACT	iv
論文目錄	v
圖目錄	vii
表目錄	x
第一章、緒論	1
1.1 研究動機與目的	1
1.2 相關研究	2
1.3 論文架構	5
1.4 系統架構及運作流程	5
第二章、影像前處理	7
2.1 背景模型與前景分割	7
2.2 影像型態學	10
2.3 連通體分析	13
2.4 身體部位分析	14
2.4.1 水平投影	14
2.4.2 膚色濾除	15

2.4.3 比例分析	17
第三章、特徵擷取及 SVM	20
3.1 HSV 基本色彩特徵	21
3.2 紋理特徵	22
3.3 SVM.....	24
3.3.1 線性 SVM	25
第四章、實驗結果與討論	28
4.1 實驗設備環境	28
4.2 系統實驗影片	29
4.3 SVM 訓練.....	31
4.4 系統實作與結果	34
第五章、結論與未來展望	40
參考文獻	42
附錄一	45
附錄二	49
附錄三	53
附錄四	57


圖目錄



圖 1-1 重大職業災害行業別分析[1]	2
圖 1-2 頭部區塊切成四等份示意圖[12]	3
圖 1-3 本研究之系統架構.....	5
圖 1-4 系統流程圖	6
圖 2-1 前景偵測結果	10
圖 2-2 結構元素示意圖	10
圖 2-3 膨脹示意圖	11
圖 2-4 膨脹結果	11
圖 2-5 侵蝕示意圖	12
圖 2-6 侵蝕結果	12
圖 2-7 斷開結果	13
圖 2-8 連通體標記完後得到每一物件的訊息	14
圖 2-9 前景影像與水平投影直方圖	15
圖 2-10 水平投影分析切割結果	15
圖 2-11 膚色像素在 NCC 色彩空間統計分佈範圍[17]	16
圖 2-12 安全帽頭部區域判斷流程	17
圖 2-13 濾除膚色的結果	17
圖 2-14 安全帽高度及前景高度比	18
圖 2-15 各部位比例關係	19

圖 3-1 特徵擷取及 SVM 之流程圖	20
圖 3-2 HSV 色彩空間	21
圖 3-3 基本的 LBP 運算	22
圖 3-4 58 種 uniform patterns	24
圖 3-5 超平面與樣本示意圖[22]	25
圖 4-1 白、藍安全帽樣本	28
圖 4-2 螢光綠、螢光橘工地背心樣本	29
圖 4-3 無工地安全帽、無背心之範例	29
圖 4-4 有工地安全帽、無背心之範例	30
圖 4-5 無工地安全帽、有背心之範例	30
圖 4-6 有工地安全帽、有背心之範例	31
圖 4-7 藍色安全帽訓練影像	32
圖 4-8 白色安全帽訓練影像	32
圖 4-9 非安全帽訓練影像	32
圖 4-10 螢光綠背心訓練影像	32
圖 4-11 螢光橘背心訓練影像	33
圖 4-12 非背心訓練影像	33
圖 4-13 系統畫面說明	35
圖 4-14 有帽子、有背心辨識結果	36
圖 4-15 僅配戴帽子辨識結果	36
圖 4-16 僅配戴背心辨識結果	36

圖 4-17 無安全帽、無背心辨識結果.....	37
圖 4-18 其餘狀況：頭戴機車安全帽辨識結果.....	37
圖 4-19 安全帽分類錯誤的影像.....	37
圖 4-20 安全背心分類錯誤的影像.....	38
圖 5-1 應用情境示意圖.....	41



表目錄

表 1-1 相關文獻特徵整理.....	4
表 4-1 各類別訓練及測試影像張數.....	32
表 4-2 混淆矩陣.....	39
表 4-3 辨識結果.....	39

第一章、緒論



1.1 研究動機與目的

近年來工地事故頻傳，營造業之重大職業災害發生比率[1]，相較於其他行業更為嚴重，如圖 1-1所示。其中，工地人員安全裝備配戴不齊為造成嚴重傷害的主要原因。為了避免悲劇一再發生，北市勞工局勞委會於96年之施政計畫[2]，推動營造工程安全視訊監控系統設置，用以提高工地安全，並可檢視勞工安全裝備是否著裝確實。目前現有的施政計畫所提出之系統僅可於災害發生後，作為勞工著裝是否確實進行檢討，或需配置一名人力用以隨時檢視人員裝備是否符合規定。然而營造業歷年來的職業傷害仍居高不下，且於96年推廣設置視訊監控系統後，仍無明顯改善，所以如何提升營造業之工地安全，仍有待加強改善。因此，本研究基於營造工程安全已架設視訊監控系統之影像，藉由人體偵測及物件辨識技術，判定勞工進入工地時是否按規定著裝，以達到更全面性的安全檢查。

本研究目的為設計一套工地安全即時監視系統，透過網路攝影機(IP-CAM)拍攝的影像，即時偵測工地入口處的工人是否配帶工地安全帽以及反光背心。首先，會於影像中定義偵測之區域即所謂之感興趣區域(Region of Interest, ROI)，系統主要的流程為當工人進入ROI時，系統即偵測到畫面中的工人，擷取所需特徵後加以辨識，如果工人所配戴的裝備符合規定，即可進入工地；如不符，則不准許其進入工地，並且發出警報通知檢查人員，藉以避免可能產生之工安事件。

監控範圍是針對工地出入口處，在攝影機固定不動且正對著工地出入口的情況下進行拍攝，一次只准許一位工人進入ROI內，以便取得工作人員完整的著裝影像進行判讀。




圖 1-1 重大職業災害行業別分析[1]

1.2 相關研究

安全帽、背心偵測技術，漸漸地廣泛用於多媒體內容分析中，像是車輛計數、檢視機車騎士有無配戴安全帽、偵測ATM使用者是否戴著安全帽及工地中人員的計數等等。然而這些物件偵測的方法，通常會抽取不同的特徵，再交由分類器進行分類，或透過特定的規則來判定物件是否存在。以下將簡介近年來的一些相關研究。

Ku等人[3]提出了一套機車計數系統，該系統以移動物體的長、寬和像素比來偵測機車物件，並利用水平和垂直投影，抽取出被遮蔽的機車。抽取出來後在其Bounding box裡設定一搜尋區域，並使用Canny邊緣偵測[4]，配合搜尋演算法來確認是否有安全帽存在。

Wen 等人[5]以影像辨識技術，應用於在ATM監視系統中，犯罪者通常會藉由安全帽來遮蔽臉部資訊，利用偵測安全帽的方式，來防範任何可疑之人。該研究基於Hough transform，提出了一套偵測圓弧形狀的演算法，並以此幾何特徵來偵測於ATM領錢的人是否穿戴安全帽，此篇的缺點就是只用幾何特徵，去驗證安全帽是否存在，但偶爾會將人頭誤判。

Chiverton[6]提出一套可以自動偵測摩托車騎士有無配戴安全帽的系統。先以背景相減法來得到機車前景，對於頭部的區域切成四小塊後，分別計算灰階直方圖及梯度直方圖[7] (Histogram of Oriented Gradient, HOG)，再將其串為一組特徵向量作為特徵，接下來使用SVM[8]辨識騎乘者是否有戴安全帽。

Silva等人[9]提出一套自動偵測無配戴安全帽機車騎士的系統，在此篇研究分為兩個階段，第一階段為偵測機車物件，第二階段偵測物件影像上是否配有安全帽。此篇研究利用可適性高斯混和模型[10]切割出前景（Adaptive Mixture of Gaussians, AMG），再利用SVM判斷該前景影像是否為機車，此處所使用的特徵為LBP；若為機車影像，則將頂部1/5的影像作為ROI，再以Circular Hough Transform偵測ROI中接近圓的區域，之後從中抽取LBP, HOG等特徵，在交由SVM判斷是否為安全帽。

Du 等人[11]採用 Adaboost 人臉偵測來尋找人臉區塊，以膚色顏色來將誤判的情形濾除，當人臉被成功偵測時，再對於人臉上方的區域，使用 HSV 色彩資訊來判斷是否有戴安全帽。

Waranusast 等人[12]針對機車側面影像，進行機車騎士計數，並偵測其是否配戴安全帽。系統的首要部分為移動物體的偵測，目的是為了把移動物體抽取出來，接著會使用 K-Nearest Neighbor(KNN) [13]來做分類，判斷是摩托車或者是其他物體，若是機車，則將頭部區域擷取下來，再從中抽取特徵，最後在再以 KNN 判斷是否有帶安全帽。該論文擷取頭部區塊後，將其切成四等份，如圖 1-2 圖 1-2 頭部區塊切成四等份示意圖所示。其中，Q1、Q4 為人的背面，Q2、Q3 為人的正面，Q3 也是人的臉部區域，特徵抽取的方式為，針對 Q1 至 Q4 分別計算曲率、平均灰階值，及針對 Q3 抽取平均色調值(Average Hue)。




圖 1-2 頭部區塊切成四等份示意圖[12]

Park 等人[14]，提出了一套可以在工地進行工人計數的方法，工人皆會穿著螢光色的工地背心，該篇論文也已此色彩資訊作為辨識特徵。首先，以背景相減法取得前景，再以 HOG 特徵和 SVM 判斷該前景是否為人的影像。若為人的影像，在從中抽取色調直方圖(hue histogram)、飽和直方圖 (saturation histogram)，在交由 KNN 進行分類，以判斷該物件是否為工人影像。

表 1-1 為上述簡介論文及所使用特徵的整理，[3]僅使用邊緣點判斷是否有安全帽存在，但其所提出的方法，受安全帽在影像中的大小、相機拍攝角度及高度等參數所影響。[5]使用幾何特徵，偵測影像中接近圓弧的部分，對於安全帽偵測而言，此方法是不足夠的，易對人頭造成誤判。[6]、[12] 所提出的灰階值，受光線影響大。而[6]、[9]所使用的 HOG，對於即時系統，其計算量過於龐大，亦不為本研究所考慮的特徵。在[11]、[12]及[14]，HSV 色彩特徵有不錯的表現，屏除易受光線影響的 Value channel，本研究以色調及飽和度，並且結合紋理特徵 LBP 作為特徵。

表 1-1 相關文獻特徵整理

文獻	特徵
[3]	Canny 邊緣偵測
[5]	Circular Hough Transform
[6]	灰階直方圖及 HOG
[9]	LBP、HOG
[11]	HSV
[12]	曲率、平均灰階值、平均色調值
[14]	色調直方圖、飽和直方圖

1.3 論文架構

本論文共分成五個章節。第一章說明本論文研究動機與目的，並探討相關研究文獻以及概述系統架構及運作流程。第二章說明本研究之模型建立、背景更新、分割前景及影像前處理等技術、並且詳細敘述如何從前景資訊判斷頭部及身體的位置。第三章介紹本研究利用何種特徵及SVM的原理。第四章為實驗結果與討論，第五章總結本論文的研究以及未來可深入的方向。

1.4 系統架構及運作流程

本研究所提出的系統主要分成四個部分，分別為(1)背景及前景分割、(2)身體部位分析、(3)特徵抽取、(4)物件分類等，如圖 1-3所示。




圖 1-3 本研究之系統架構

根據圖 1-3系統分成四個架構，其運作流程如圖 1-4所示。輸入影像後，使用背景相減法來分割背景和前景，並持續的更新背景以維持分割的準確性。當分離出前景後，需對其進行分析，進而得到頭部區域影像以及身體區域的影像，再來

進行特徵抽取，最後以訓練的SVM分類器來做物件的辨識。




圖 1-4 系統流程圖

第二章、影像前處理



本章節中，我們需將畫面中移動的物體擷取出來，並判斷前景是否為人的影像，若為人的影像，再分析安全帽及背心的位置。背景模型的建立以及擷取出畫面移動中的前景將在2.1節說明；2.2及2.3節簡述前處理方法，包含影像型態學處理、連通元件分析，藉以獲得前景影像的初步資訊；2.4節則介紹身體部位的分析，如何定位安全帽及背心的所在位置。

2.1 背景模型與前景分割

在視訊監控領域的應用中，如何將前景和背景分離往往是重要的一環。在攝影機固定的情況下，背景的變化是緩慢的，大多都是受到光照、風吹等之影響，所以本研究使用單一高斯模型來對背景建模並且結合[15]所提出的色度(chromaticity)及梯度(gradient)的資訊來降低誤判的狀況，其原理如下所述。

一般而言，給定一段影像片段，在0到t秒這一段時間內，影像中的每個像素點的RGB分佈皆滿足高斯分布。故在t+1秒時，只要將新的影像上的每一點像素和原先像素所統計的高斯模型進行比較，就可以知道該像素點屬於背景還是前景。但有些情形會違反上述所說的高斯分布，像是樹葉晃動、水波漣漪等等情況。為了減少這些前景誤判的狀況，常常會利用高斯混和模型來解決此類問題，但相對的也會帶來龐大的運算量。由於本研究需要達到即時性的辨識，所以採用單一高斯模型來模擬背景資訊。

由於需對每個像素建立高斯背景模型，我們採用對每個像素點分別儲存 $[\mu_r, \mu_g, \mu_b, \sigma_r^2, \sigma_g^2, \sigma_b^2]$ 。其中， μ_r, μ_g, μ_b 分別為RGB的平均值， $\sigma_r^2, \sigma_g^2, \sigma_b^2$ 為RGB的變異數。為了要將前景從影像中抽取出來，可利用像素點和高斯模型的距離來加以判斷，若與平均值的距離大於三倍的標準差，則為前景，否則為背景，其公式如公式(2.1)所示。

$$\begin{cases} \text{foreground} & \text{if } |r - \mu_r| > 3 \times \max(\sigma_r, \sigma_{rcam}) \\ & \text{if } |g - \mu_g| > 3 \times \max(\sigma_g, \sigma_{gcam}) \\ & \text{if } |b - \mu_b| > 3 \times \max(\sigma_b, \sigma_{bcam}) \\ \text{background} & \text{otherwise} \end{cases} \quad (2.1)$$



其中， r 、 g 、 b 分別為新像素點的RGB值， μ_r, μ_g, μ_b 為背景影像所統計出來的RGB平均值， $\sigma_r, \sigma_g, \sigma_b$ 為統計之RGB標準差。因為攝影機本身在拍攝的過程中也會產生一些雜訊，所以我們會用 $\sigma_{rcam}, \sigma_{gcam}, \sigma_{bcam}$ 來考量雜訊存在的情形。為了讓光線變化不影響到前景切割的準確性，背景模型需要一直進行更新，更新的方式如公式(2.2)所示。

$$\begin{aligned} \mu_{t+1} &= \alpha \mu_t + (1 - \alpha) z_{t+1} \\ \sigma_{t+1}^2 &= \alpha(\sigma_t^2 + (\mu_{t+1} - \mu_t)^2) + (1 - \alpha)(z_{t+1} - \mu_{t+1})^2 \end{aligned} \quad (2.2)$$

平均值和變異數是隨著時間變動， z_{t+1} 是在時間點 $t+1$ 時所量測出來的RGB值 $(r_{t+1}, g_{t+1}, b_{t+1})$ ，常數 α 是控制整體的學習律，數值越小背景模型更新的速度會越快，亦即代表新的背景像素佔有較高的權重，而 α 值會介於 $[0,1]$ 之間。

陰影的出現會造成像素灰階值(gray scale)有顯著的改變，但在色度(chromaticity)上則不太會有影響，若以上述方法切割出來的前景，則也會將陰影誤判為前景。為了正確分離前背景的背景，我們只要同時觀察灰階值上是否有明顯變化且比較色度的變化情況下，即可得知該像素是否為陰影部分。利用文獻[15]提出的方法，以梯度(gradient)及色度(chromaticity)來取代原先利用RGB建立之高斯模型以解決此問題。色度(chromaticity)計算如公式(2.3)。

$$\begin{aligned} r_c &= r / (r + g + b) \\ g_c &= g / (r + g + b) \end{aligned} \quad (2.3)$$

同時，我們也需要計算 $\mu_{rc}, \mu_{gc}, \sigma_{rc}^2, \sigma_{gc}^2$ ，要改用色度執行背景相減法的方式和公式(2.1)相同，僅需用公式(2.3)所計算的色度取代原先的RGB值即可，如公式(2.4)。

$$\begin{cases} \text{foreground} & , \text{if } |r_c - \mu_{rc}| > 3 \times \max(\sigma_{rc}, \sigma_{rcam}) \\ & , \text{if } |g_c - \mu_{gc}| > 3 \times \max(\sigma_{gc}, \sigma_{gcam}) \\ \text{background} & , \text{otherwise} \end{cases} \quad (2.4)$$



但色度如在前景和背景都屬同色系時是毫無差異的，像是深綠色的褲子經過淺綠色草地，此時他們的色度是差不多的，所以[15]提出，可以利用梯度資訊來改善同色系的問題。在此，我們利用sobel來計算x和y方向的梯度，也須計算 $(\mu_{xr}, \mu_{yr}), (\mu_{xg}, \mu_{yg}), (\mu_{xb}, \mu_{yb}), \sigma_{gr}^2, \sigma_{gg}^2, \sigma_{gb}^2$ ，此外我們也需計算整張影像的變異數 $\overline{\sigma_{gr}}^2, \overline{\sigma_{gg}}^2, \overline{\sigma_{gb}}^2$ 。結合梯度的背景相減法計算方式如下，如有一像素值 $x = (r, g, b)$ ，經由sobel計算出來的梯度為 $x = (r_x, r_y), (g_x, g_y), (b_x, b_y)$ ，再經由公式(2.5)可判斷出前景背景的資訊。

$$\begin{cases} \text{foreground} & , \text{if } \sqrt{(r_x - \mu_{xr})^2 + (r_y - \mu_{yr})^2} > 3 \times \max(\sigma_{gr}, \overline{\sigma_{gr}}) \\ & , \text{if } \sqrt{(g_x - \mu_{xg})^2 + (g_y - \mu_{yg})^2} > 3 \times \max(\sigma_{gg}, \overline{\sigma_{gg}}) \\ & , \text{if } \sqrt{(b_x - \mu_{xb})^2 + (b_y - \mu_{yb})^2} > 3 \times \max(\sigma_{gb}, \overline{\sigma_{gb}}) \\ \text{background} & , \text{otherwise} \end{cases} \quad (2.5)$$

所以當公式(2.4)和公式(2.5)判定為真時，則切割出來的影像就是不含陰影的前景，接著，我們會利用影像形態學處理及連通體分析來讓前景影像更為完整，而影像型態學之方法將於下面小節介紹。而圖 2-1為利用兩種方式所偵測之前景背景，子圖 (a) 為原始影像，子圖 (b) 為利用高斯背景模形所得之結果，可以看到，部分背景背誤判為前景。子圖 (c) 則為利用梯度色度模型所取得之前景資料，可以看出其前景判定較高斯背景模型來的準確。




(a)原圖 (b) 利用 RGB 來建立高斯背景模型 (c) 梯度色度模型

圖 2-1 前景偵測結果

2.2 影像型態學

完成上一節所介紹的前景分割後，得到的前景影像，往往會因為偵測的不完整而造成影像破碎或者因為一些誤判而出現的小雜訊等等（如圖2-1(c)所示），因此我們會利用型態學來處理修補破碎區塊以及消除小雜點。

膨脹(dilation)及侵蝕(erosion)為影像型態學中最基本的運算。進行運算時，會由左而右、從上到下的順序掃描每個像素，並與結構元素(structure element)所涵蓋的相鄰像素做運算。其中，結構元素可分4-連通(4-connected)、8-連通(8-connected)，本研究使用8-連通的結構元素，其結構示意圖如圖 2-2所示。



(a) 8-連通結構元素

(b) 4-連通結構元素

圖 2-2 結構元素示意圖

膨脹及侵蝕的操作方式及公式分別描述如下：



(1) 膨脹：

假設 A 為二值化影像、 B 為結構元素，先將 B 視為一遮罩，在由左而右、從上到下逐一對 A 中每個像素進行掃描，若在 B 所涵蓋的範圍內有任何像素值為 1，則將 A 中正在掃描的像素點也設為 1，否則繼續往下個像素掃描。以圖 2-3 為例，結構元素 B 的邊長為 $d/4$ 單位，經過膨脹運算後，二值化影像 A 將會向外增加 $d/8$ 的長度。使用結構元素 B 來膨脹二值化影像 A ，記做 $A \oplus B$ ，其邏輯運算式為公式 (2.6)。圖 2-4(a) 子圖為原始影像，經過膨脹運算之結果如右子圖(b)所示。

$$A \oplus B = \{z \mid (\hat{B})_z \cap A \neq \varnothing\} = \{z \mid [(\hat{B})_z \cap A] \subseteq A\} \quad (2.6)$$




圖 2-3 膨脹示意圖



(a) 原始影像

(b) 膨脹後

圖 2-4 膨脹結果

(2) 侵蝕：

假設 A 為二值化影像、 B 為結構元素，先將 B 視為一遮罩，在由左而右、從上到下逐一對 A 中每個像素進行掃描，若在 B 所涵蓋的範圍內有任何像素值為 0，則將 A 中正在掃描的像素點也設為 0，否則繼續往下個像素掃描。以圖 2-5 為例，結構元素 B 的邊長為 $d/4$ 單位，經過侵蝕運算後，二值化影像 A 將會向內減少 $d/8$ 的長度。使用結構元素 B 來侵蝕二值化影像 A ，記做 $A \ominus B$ ，其邏輯運算式為公式(2.7)。圖 2-6 (a)左子圖為原始影像，經過侵蝕運算之結果如右子圖(b)所示。

$$A \ominus B = \{z \mid (B)_z \subseteq A\} = \{z \mid (B)_z \cap A^c = \varnothing\} \quad (2.7)$$




圖 2-5 侵蝕示意圖



(a) 原始影像

(b) 侵蝕後

圖 2-6 侵蝕結果

斷開(opening)與閉合(closing)則是由膨脹及侵蝕組合而成的運算。斷開先對影像進行侵蝕再做膨脹，主要是用來消除雜訊、平滑輪廓；閉合先對影像進行膨脹再做侵蝕，主要可用來填補裂縫。本篇論文使用了斷開運算，由圖 2-7(b)可看出雜訊被清除、也修補了原圖中破碎的影像。



(a) 原始影像

(b) 斷開結果圖

圖 2-7 斷開結果

2.3 連通體分析

連通元件標記(Connected Component Labeling)[16]用於將影像中鄰近相鄰的像素進行標記，同一個物件給予相同的標籤值，不同的物件則有著不同的標籤值，藉此獲得每個被標記物件的面積、高度及寬度等資訊。常用的方法分為4-連通物件標記法(4-connected component labeling)及8-連通物件標記法(8-connected component labeling)。

4-連通物件標記法考慮上下左右相鄰的像素；而8-連通物件標記法除了上下左右相鄰的像素以外，還需考慮左上、左下、右上及右下的斜角像素。經過前面幾節所介紹的步驟，得到二值化影像後，本研究透過8-連通物件標記法來標記影像中的前景，以區分影像中不同的物件，則我們可以透過對面積、長寬設立閾值的方式，來過濾我們不需要的物件。同時，我們也可利用連通體來得到每一個前景的高度，以利之後部位判定時所使用，如圖 2-8。




圖 2-8 連通體標記完後得到每一物件的訊息

2.4 身體部位分析

為了要讓系統可以正確辨識畫面中的人物是否有戴安全帽及安全背心，必須先將頭部以及身體位置進行定位。因此利用水平投影來切割出頭部區塊，並且結合膚色偵測，將皮膚區域濾除，以得到臉部上方頭髮部位的影像。我們利用上述方法獲得臉部上方區塊後，觀察其長寬與前景高度的關係，可以發現它們維持著一定比例的關係，所以之後可以藉由前景高度的比例，即可判定頭部上方及身體的區塊，如此可以減少運算量及計算時間。

2.4.1 水平投影

前景切割並且經過型態學、連通體分析，可得如圖 2-9左子圖之結果。若以水平投影方式計算每一個橫列白色像素的數量，可得如圖 2-9右子圖之直方圖結果。直方圖的縱軸是每一個橫列位置，橫軸則是白色像素所累積的總數量。

由水平投影直方圖的結果，可以發現其曲線變化會有三個明顯的波峰，分別代表頭部、上半身及下半身的像素所累加的值，也就是說，這三個部位可以藉由波谷的位置來進行切割的動作，而切割的結果如圖 2-10所示。




圖 2-9 前景影像與水平投影直方圖



圖 2-10 水平投影分析切割結果

2.4.2 膚色濾除

透過水平投影，可以將頭部區域判斷出來，但正確所需的部位是臉部上方頭髮的區域，因此透過濾除膚色的區域，即可達到此目的。在膚色過濾的步驟，我們利用文獻[17]所提出的方法，在正規化色彩空間(Normalized Color Coordinates, NCC)偵測膚色的像素。影像中紅色及綠色兩顏色正規化，目的在可以減少光源對

色彩判斷的影響、並降低對亮度的依賴。其方法是將其方法是將原影像中各像素之RGB可利用公式(2.8)，將其轉換成NCC之結果。

$$\begin{aligned} N_r &= \frac{R}{R+G+B} \\ N_g &= \frac{G}{R+G+B} \end{aligned} \quad (2.8)$$

圖 2-11為膚色像素在NCC色彩空間上分布的範圍，其中橫軸為正規化紅色(Nr)、縱軸為正規化綠色(Ng)，其值介於0~1之間，藍色點即為膚色分布的區域。




圖 2-11 膚色像素在 NCC 色彩空間統計分佈範圍[17]

由圖 2-11可得知，膚色像素的分佈相當地集中，故可利用一次直線方程式及二次曲線方程式來定義其邊界。我們利用一條二次曲線方程式及兩條一次直線方程式來將膚色範圍做分割。白色像素可能落在三條方程式所包圍的範圍內，因需排除此狀況，所以我們以白色點為中心，半徑為0.02的圓形範圍，來避免接近白色的像素被誤判成膚色，其判斷公式如(2.9)至(2.13)所示，當S=1即判定為膚色像素。

圖 2-13即原圖頭部區域經NCC膚色過濾的結果。

$$S = \begin{cases} 1 & \text{if } (N_g < Q_{upper1}) \& (N_g < Q_{upper2}) \& (N_g < Q_{lower}) \& (w \geq 0.0004) \\ 0 & \text{otherwise} \end{cases} \quad (2.9)$$

$$Q_{upper1} = -1.468N_r + 1.18 \quad (2.10)$$

$$Q_{upper2} = -0.05657N_r + 0.3756 \quad (2.11)$$

$$Q_{lower} = 0.8458N_r^2 - 1.183N_r + 0.6273 \quad (2.12)$$

$$w = (N_r - 0.33)^2 + (N_g - 0.33)^2 \quad (2.13)$$



圖 2-12 安全帽頭部區域判斷流程

圖 2-12為獲取安全帽區塊的處理流程，藉由背景相減法得到移動中的前景影像，再透過水平投影，可從第一個波谷進行切割以獲取頭部區域，之後藉著濾除膚色像素以得到臉部上方的區塊。



圖 2-13 濾除膚色的結果

2.4.3 比例分析

完成前述步驟，可以由前景得到臉部上方區塊的位置訊息。但若用此方法來

切割，相對的也會帶來較大的運算量，由我們的實驗顯示，可以利用前景高度以一定的比例來獲取頭部上方以及上半身區塊，藉此以減少本系統的運算量，以下將說明所使用之實驗方法。

觀察一段頭戴安全帽的人物走動之連續影像，發現當人物往攝影機的方向前進時，影像中安全帽的高度和人物高度的變化如圖 2-14所示，橫軸為人物至攝影機的距離，縱軸為頭部長度與前景影像高度的比值。由結果可以發現，隨著畫面中人物與攝影機的距離越來越近，其比值分布皆呈現穩定的狀態，因此我們可以利用一組比例來動態定位安全帽及背心位置。




圖 2-14 頭部長度及前景高度比

圖 2-15為各部位的比例關係，統計許多影像後，歸納出幾組數據，之後將依照以下所列的比例，進行動態定位安全帽及背心的位置。以下為各組數據的說明：

- (1) Height：前景人物高度。
- (2) Width：前景人物寬度。
- (3) HL：頭部長度，為0.31倍的Height
- (4) HW：頭部寬度，HL除以1.2
- (5) HH：安全帽高度，為0.35倍的HL

(6) BL：背心長度，2.3倍的HL

(7) BW：背心寬度，0.8倍的Width




圖 2-15 各部位比例關係

第三章、特徵擷取及 SVM



特徵擷取指從影像中擷取一些可以代表被辨識物體的視覺特徵，視覺特徵可包含形狀、色彩和紋理等等。視覺特徵又可以分為對整張影像(Global)或部分區域(Local)，前者在擷取特徵時，需考慮影像中的每一個像素，例如：整張影像的色彩直方圖，而後者則只針對影像的部分區域進行特徵的擷取。本系統採用對整張影像抽取特徵的方式，以HSV及LBP (Local Binary Pattern)直方圖作為主要特徵。並且交由SVM (Support Vector Machine)進行訓練及分類。其系統流程圖，如圖 3-1 所示。




圖 3-1 特徵擷取及 SVM 之流程圖




3.1 HSV 基本色彩特徵


攝影機所拍攝的影像資訊，通常是以RGB色彩空間來表示。但是RGB易受光線所影響，為了避免此問題帶來的困擾，所以本研究所採用對光線強弱較不敏感的HSV色彩空間[18]。

HSV色彩空間，對人類而言較易理解，其優點是能將亮度(Value)成分從色彩資訊中獨立出來，而色彩資訊又分為色調(Hue)及飽和度(Saturation)。

色調為我們平常指的顏色。飽和度為色彩的純度，飽和度越高則色彩越純，越低則逐漸變淡直至變為灰色。亮度為光線所照成的明暗度。圖 3-2為HSV色彩空間的基本色盤。HSV三者間的關聯度小，故非常適合做影像處理使用。由於彩色影像儲存時，大部分是以 RGB 來表示，因此必須將RGB值轉換成HSV值，其轉換如公式(3.1)所示。



(a) HSV 色環屬性圖



(b) HSV 圓錐體色彩屬性圖

圖 3-2 HSV 色彩空間

$$\begin{aligned}
 V &= \max(R, G, B) \\
 S &= \frac{(V - \min(R, G, B))}{V} \\
 H &= \begin{cases} \frac{(G - B) \times 60}{S} & , \text{if } V = R \\ 180 + \frac{(B - R) \times 60}{S} & , \text{if } V = G \\ 240 + \frac{(R - G) \times 60}{S} & , \text{if } V = B \end{cases}
 \end{aligned} \tag{3.1}$$

本研究利用此色彩空間可以將亮度獨立出來的優點，所以辨識時以色調和飽

和度作為主要特徵。



3.2 紋理特徵

區域二元圖樣(Local Binary Patterns, LBP)[19]是由Ojala等人於1996年提出，是一個用來描述紋理的特徵，其優點是計算簡單及快速，非常適用於本研究所提出的即時辨識系統，而在許多研究證實LBP在圖像檢索、人臉辨識、物件辨識等等領域上有不錯的效果。

區域二值化模型計算方法如下，首先將圖片轉成灰階，再依序將每一個像素當成中心點，並且以中心點為閾值(threshold)與其周圍 3×3 區塊內的像素點進行比較，若鄰近的點大於閾值，則將此點標記為1，反之則將它標記為0，圖 3-3為一典例計算例。標記完後即可得到一組二進制數字，即為該點之LBP特徵值。




圖 3-3 基本的 LBP 運算

LBP數學定義式如下：

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} B_p \cdot 2^p \quad (3.2)$$

$$B_p = \begin{cases} 1 & , g_p - g_c \geq 0 \\ 0 & , g_p - g_c < 0 \end{cases} \quad (3.3)$$

其中， g_c 為中心點像素 (x_c, y_c) 的灰階值， P 為取樣點的數目， R 為取樣點至中心點的距離， g_p 為與中心點像素距離 R 的某一取樣點之灰階值。本研究採用半徑 $R=1$ ，取 $P=8$ 個點之LBP特徵值，共有 2^8 種pattern。依序計算每一像素點的LBP特徵值，再統計每個LBP特徵值出現的次數作為直方圖，以此作為描述該圖片紋理

的特徵。

由上述步驟，可以觀察到取樣點數8的LBP所產生的pattern共有256種，而取樣點的數目若變大，則LBP特徵值的範圍也會變大。例如在 5×5 的區域內有16個取樣點，共會產生 $2^{16} = 65536$ 種pattern。一旦特徵值的範圍變大，則對於描述紋理來說是越不利的，也就是說當我們在統計LBP特徵值直方圖時，可能使各統計結果之描述不足。

為了解決這種問題，Ojala提出了Uniform pattern[20]來改良原始版本的LBP。Uniform pattern即要求LBP特徵值所產生的0與1數列中，最多僅可有兩次從1到0或從0到1的轉變，例如:00001111、10001111 和 11111111。根據他們的實驗顯示，當 $P=8$ 、 $R=1$ 之LBP時，uniform patterns將佔原有LBP的90%；若使用 $P=16$ ， $R=2$ 的LBP則佔70%。通過這樣的改進，原有的LBP pattern種類減少許多，pattern數量由原來的 2^P 降至 $P \times (P-1) + 3$ 種，以 3×3 的區域內有8個取樣點的LBP pattern數量將由256降至59種，其中58種為uniform patterns，如圖 3-4。原先LBP中不屬於uniform pattern的則集中歸類成同一種類，所以共有59種，這樣不僅可以使特徵的維度降低且也能使雜訊的影響減少。在此本研究也以uniform pattern來表示紋理的特徵。




圖 3-4 58種uniform patterns

3.3 SVM

支持向量機[21](SVM)是近年來熱門的機器學習演算法，常用於處理二元分類問題(Binary classification)，並且廣泛應用於影像辨識與文本分類等領域上。主要運作分為訓練(training)及預測(prediction)兩個階段，由於SVM屬於監督式學習(Supervised learning)演算法，所以我們在訓練階段時，需先對已知資料進行標記的動作，再從其中去學習，並建立一個超平面(hyperplane)以分類資料。而在預測階

段中，用訓練階段所得到的超平面，來對未知的資料進行分類，盡可能的將每一筆資料分類到正確的類別。

3.3.1 線性 SVM

一般而言，SVM所面對的問題分為兩類，一類屬於線性可分割(linearly separable)，另一類則為線性不可分(linearly non-separable)，本研究所面對的分類屬於線性可分割，故在此僅介紹線性可分的SVM，其原理如下。

假設我們有一組訓練資料為 $\{x_i, y_i\}$ ， $i = 1, 2, \dots, k$ 且 $x_i \in R^n$ 、 $y_i \in \{-1, +1\}$ ，其中 $\{x_i\}$ 為特徵向量，而 $\{y_i\}$ 稱為標籤(label)。在線性可分的情況下，我們可以從訓練資料中，找出一可以將它們完整分開且距兩類資料離夠遠的的超平面，以數學表示為 $w \cdot x + b = 0$ ，其中 w 為超平面的法向量、 b 表示位移量。超平面與訓練資料的關係如圖 3-5所表示。




圖 3-5 超平面與樣本示意圖[22]

在高維度空間中，兩類資料間可能存在著許多超平面，故我們需要找出一個與兩類資料距離最遠的最佳超平面，以避免往後遇到過於相似的資料而造成誤判的結果。

最佳超平面可透過解下列問題獲得：

Minimize

$$\frac{1}{2} \|w\|^2 \quad (3.4)$$

Subject to

$$y_i (w \cdot x_i + b) \geq 1 \quad i = 1, 2, 3, \dots, n \quad (3.5)$$

我們利用Lagrange mutipliers method來解此問題，

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (w \cdot x_i + b) - 1] \quad (3.6)$$

其中， α_i 為對應於 x_i 的Lagrange乘數，接下來使用 Lagrange 乘數法，即求式(3.6)

的偏微分：

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^n \alpha_i y_i x_i = 0 \quad (3.7)$$

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^n \alpha_i y_i = 0 \quad (3.8)$$

得到：

$$w = \sum_{i=1}^n \alpha_i y_i x_i \quad (3.9)$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (3.10)$$

之後將式(3.9)、式代回式(3.6)可得：

$$\begin{aligned} L(w, b, \alpha) &= \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (w \cdot x_i + b) - 1] \\ &= \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) + \sum_{i=1}^n \alpha_i \\ &= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \end{aligned} \quad (3.11)$$



因為Wolfe二元性(Wolfe dual)可將上述式子轉為其對偶問題，如下所示：

Maximum

$$L(w, b, \alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (3.12)$$

Subject to

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad \alpha_i \geq 0, i = 1, 2, \dots, n \quad (3.13)$$

此為二次規劃(quadratic programming, 簡稱QP)的問題。因為(3.5)式的限制式有不等式，因此 Lagrange 乘數有限制式 $\alpha_i \geq 0$ ，這種情況符合 Karush-Kuhn-Tucker 條件(簡稱 KKT 條件)，藉由KKT條件可知，上式其解必須滿足

$$\alpha_i \{y_i (w \cdot x + b) - 1\} = 0, \quad i = 1, 2, 3, \dots, n \quad (3.14)$$

由於只有 $\alpha_i \geq 0$ 的樣本對於分類才有作用，因此我們稱呼這些 $\alpha_i \geq 0$ 的樣本為支撐向量(Support vector)。而最後的分類函數為：

$$f(x) = \sum_{i=1}^n y_i \alpha_i (x \cdot x_i) + b \quad (3.15)$$

根據 $f(x)$ 的正負來決定判斷的結果，其中 α_i 、 y_i 、 x_i 、 b 皆為訓練資料所得參數。



第四章、實驗結果與討論



以上述章節所介紹的方法來實作本研究之工地安全監控系統，本章將詳細介紹實驗設備器材、實驗所拍攝的環境、系統訓練方式以及實際模擬的辨識結果。

4.1 實驗設備環境

系統執行的硬體環境架構在Intel Core i5-2557M 1.7GHz以及4GB的記憶體，作業系統為Mac OS X 10.9，而用來開發的程式語言為Python 2.7版本，並且結合OpenCV以及台大林智仁老師實驗室的LIBSVM[8]。實驗影像來源為IPUX ICS1330網路攝影機(IPCAM)於實驗室所拍攝的影片，以解析度為320x240的像素值作為畫面大小，拍攝速率為每秒三十張影格(frame)，實驗影片是在同一地點不同時間且位置及高度固定的情況下所拍攝。實驗影片中，用於模擬工地人員所穿戴的配備，以工地安全帽及工地背心為主，安全帽分為白色及藍色，如圖 4-1，而工地背心則以螢光紅、螢光綠背心來做為實驗的辨識目標，如圖 4-2所示。



圖 4-1 白、藍安全帽樣本



圖 4-2 螢光綠、螢光橘工地背心樣本

4.2 系統實驗影片

本研究所拍攝之視訊資料庫，內容為模擬工地出入口人員進出的狀況，其中人員的穿著以「無工地安全帽、無背心」、「有工地安全帽、無背心」、「無工地安全帽、有背心」、「有工地安全帽、有背心」隨機出現在影片中，如圖 4-3至圖 4-6 所示。




圖 4-3 無工地安全帽、無背心之範例



圖 4-4 有工地安全帽、無背心之範例




圖 4-5 無工地安全帽、有背心之範例




圖 4-6 有工地安全帽、有背心之範例

4.3 SVM 訓練

本研究用於SVM的訓練影像，一部分由google圖片搜尋工地工人照片切割而得，另一部分為從自行錄製影片中進行擷取，其中包含不同亮暗光線以及不同款式的安全帽和背心，如圖4-7至4-12所示，其主要目的為增加系統對兩者有更好的適應度，白安全帽、藍安全帽共1258張、非安全帽1179張、螢光橘、螢光綠背心共369張、非背心為545張，而測試影像的部份，安全帽419張、非安全帽392張、背心122張、非背心169張，各類別訓練及測試影像張數表 4-1呈現所有訓練及測試影像之數目資訊。



表 4-1 各類別訓練及測試影像張數

	訓練張數	測試張數
安全帽	1258	419
非安全帽	1179	392
安全背心	369	122
非安全背心	545	169



圖 4-7 藍色安全帽訓練影像



圖 4-8 白色安全帽訓練影像



圖 4-9 非安全帽訓練影像



圖 4-10 螢光綠背心訓練影像



圖 4-11 螢光橘背心訓練影像



圖 4-12 非背心訓練影像

用來輸入至SVM的訓練特徵為HS直方圖及LBP直方圖。HS直方圖為從訓練影像中所統計出的色調直方圖(hue histogram)及飽和直方圖(saturation histogram)，再將兩者串接形成一組特徵向量，接著，我們分別將H及S直方圖的維度分為8、16、32、64、128、256 bins。而LBP直方圖以uniform pattern所改良的LBP直方圖作為特徵，維度數為59。

為了比較不同特徵的辨識效果，我們先以HS直方圖做為特徵，其結果如附錄一及二所示。從實驗數據可知，在安全帽影像中所訓練出來的模型，以train_helmet_data_128_256、train_helmet_data_256_256兩組有最高的準確率98.767%，我們取維度較小的那一組（即train_helmet_data_128_256）。在安全背心影像中所訓練出來的模型，train_vest_data_256_16及train_vest_data_256_128有最高96.9012%的準確率，但我們所挑選的模型為train_vest_data_256_128，因為此組模型有著較高的precision，而挑選較高precision的原因是我們不希望在系統運行當中，有過多false positive產生，即放行任何未配戴安全裝備的人員進入工地，在工地安全的應用情境裡，不允許任何配戴不全的人員通過入口，所以才以precision來作為辨識的準則而非recall的原因。

接著，在將LBP直方圖串接於HS直方圖之後，其結果如表附錄三及附錄四所示。根據訓練結果顯示，安全帽影像所訓練出來的模型，以train_helmet_data_8_128_lbp、train_helmet_data_64_128_lbp及

train_helmet_data_128_128_lbp，此三組有著最高的準確率，其recall和precision也相同，故我們挑選維度最少的train_helmet_data_8_128_lbp。安全背心影像所訓練的模型，train_vest_data_8_128_lbp有著最佳的表現，其準確率97.5945%。

總結一下，若以HS直方圖作為主要特徵，在安全帽的部份，將其維度分成128、256時有較好的結果，而安全背心的部份則是將Hue分為256個維度、Saturation為128維度時有比較好的表現。將LBP加上後，不論安全帽或背心部分，皆以8維和128維的組合會有最好的效果，其準確率皆比單純只用HS直方圖來得高，故本研究以HS結合LBP來作為特徵，並且以train_helmet_data_8_128_lbp、train_vest_data_8_128_lbp，作為系統之辨識模型。

4.4 系統實作與結果

本系統可由使用者定義所要偵測的ROI，以本研究的使用情境為例，我們會將ROI設置於閘門入口處，如此一來可於工人進入閘門時，系統便可即時偵測工人身上的裝備，若工人配戴符合的工地安全帽以及工地背心，則系統則發出通過的訊號，允許閘門開啟。否則，則發出警報。

ROI的設置如圖4-13所示，在底部1/4高度的地方會設定一條偵測線，當畫面中的工人，踩到此線時才會啟動偵測。當偵測啟動時，系統會自動偵測畫面中的工人，是否有配戴正確的配備，以下圖為例，畫面中的人物戴著白色工地安全帽，沒有穿任何工地背心，此時，系統則以綠色框來框安全帽的區域，表示是符合我們所定義的安全帽影像，而身體部份則以紅色框框出，這代表他並沒有按照規定穿著工地背心，此時即可發出警報通知工地管理者。



圖 4-13 系統畫面說明

實驗之系統流程圖如圖 1-4所示，首先輸入我們所錄製的模擬影片，經由背景相減法後，獲得正在移動目標物的二值化影像，再對目標物二值化影像進行closing的動作，主要目的為填補偵測所造成的破洞以及缺口，接著進行連通體分析，便能獲得目前畫面中共有幾個物件存在，以及每一個物件所對應的相關訊息，像是所佔面積、長度、寬度、長寬比等等，有了這些資訊也易於濾除掉不相關的物件。

有了前景物件的相關訊息後，利用2.4節所介紹的技術，透過前景的長度、寬度來擷取臉部上方的區塊以及身體區塊，再分別從中抽取HS直方圖以及LBP直方圖輸入SVM進行分類，即可得知兩者是否屬於安全帽以及背心。以下介紹辨識之結果。

正確被分類的影像：




圖 4-14 有帽子、有背心辨識結果




圖 4-15 僅配戴帽子辨識結果




圖 4-16 僅配戴背心辨識結果




圖 4-17 無安全帽、無背心辨識結果



圖 4-18 其餘狀況：頭戴機車安全帽辨識結果

分類錯誤影像：

(1) 工地安全帽：



圖 4-19 安全帽分類錯誤的影像

(2) 工地背心：




圖 4-20 安全背心分類錯誤的影像

圖 4-14至圖 4-18為判斷正確的情況，其中圖 4-18右為頭戴機車安全帽，身穿和螢光綠工地背心相似顏色的T恤，由於我們所使用的特徵不光只有顏色特徵，結合紋理特徵後能將顏色相似的但非我們所定義的安全帽排除在外。

在分類錯誤的影像中，圖 4-19為頭戴白色安全帽，但在光源正下方產生反光導致前景分割不完全，影響後續步驟造成錯誤的結果。圖4-20右上、左下、右下三張，皆非以正面立正的站姿來觸發偵測，導致身體分析時切割到錯誤的區塊進而誤判。由以上觀察，偵測錯誤的情況，站姿影響成分佔很大，身體分析前置步驟的不完全，使得系統在擷取頭部上方影像以及身體區塊影像時，是從不正確的位置獲得，當然也就會造成錯誤的判斷，由我們的實驗結果看來，過程中沒有任何false positive產生，即系統並無將任一未配戴正確的影像誤判為有配戴正確，在工地安全的應用情境上，可以有效的偵測出沒有配戴完全的人員。

在機器學習領域，表 4-2為一種可視化演算法效能的工具，特別用於監督式學習上。其中，每一行為實際所屬的類別，每一橫列為分類器所預測的結果。本研究以精準率(Precision)、召回率(Recall)及準確率(Accuracy)來做為評估的準則，其計算方法如式(4.1)、式(4.2)、式(4.3)所示。

表 4-2 混淆矩陣

預測類別	實際類別	
	Positive	Negative
Positive	True Positive	False Positive
Negative	False Negative	True Negative

$$Precision = \frac{TP}{(TP + FP)} \quad (4.1)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (4.2)$$

$$Accuracy = \frac{(TP + TN)}{(TP + FP + TN + FN)} \quad (4.3)$$

在所錄製的影片中，其辨識的結果如表 4-3所示。

表 4-3 辨識結果

	TP	FN	TN	FP	Precision	Recall	Accuracy
安全帽	26	2	33	0	1	0.93	0.97
安全背心	33	4	24	0	1	0.89	0.93

第五章、結論與未來展望



近年來工地事故頻傳，營造業之重大職業災害發生比率，相較於其他行業更為嚴重。其中，工地人員裝備安全配戴不齊為造成嚴重傷害的主要原因。為了避免悲劇一再發生，本論文提出一套工地安全監控系統，用以判定勞工進入工地時是否按規定著裝，以達到更全面性的安全檢查。

本論文主要分為三大部分：影像前處理、特徵擷取及辨識。首先，以網路攝影機拍攝影像後，透過背景相減法擷取移動的前景影像，利用影像型態學清除雜訊、修補破碎區塊，再由連通體分析，得到連通元件相關資訊，之後便可藉由前景高度動態定位出頭部及軀幹位置，接著再各別抽取色調直方圖、飽和直方圖以及LBP作為特徵，再交由SVM進行分類。實驗結果顯示，本系統使用色彩特徵及紋理特徵的組合，可以有效的辨識工地安全帽及工地背心，其準確率分別為97%和93%，平均執行時間為270毫秒。

本研究中，仍有幾點改善空間：

1. 白色安全帽在光源底下的反光，會使背景偵測切割得不完整，導致兩個部位切割不正確，進而造成分類錯誤，在可以接受的執行時間下，可考慮更複雜的前景抽取的方法。
2. 在目前的情境下，工地可利用連動柵欄設計(如圖 5-1)，意即在一個ROI內，限制只能有一人接受偵測，現階段尚未考慮到後方還有另一人員存在的情況，未來可以加入切割人群的演算法，對最前面的目標物進行辨識。
3. 目前只針對安全帽及背心兩樣裝備做偵測，往後可加入其他裝備辨識，如工地手套、腰帶、鋼頭鞋等，以完善此系統。
4. 加入人臉辨識，不僅可以以人臉資訊來定位人物位置，也可於勞工進入工地時，記錄進出入口的相關訊息，如：進出工地時間、統計工地內現有人數。當勞工被判定未依規定著裝時，也可利用人臉辨識結果，獲取該名勞工資訊。




圖 5-1 應用情境示意圖

參考文獻



- [1] 勞委會 101 年報職災千人率, <http://www.cla.gov.tw/site/business/41733649/4226b8a3/51a7f659/files/%C2%BE%A8%A4d%A4H%B2v101m51~58.xls>.
- [2] 勞動安全視訊監控系統設置、勞動檢查即時監督管理系統說明, <http://www.doli.taipei.gov.tw/ct.asp?xItem=1732660&ctNode=12871&mp=116021>.
- [3] M.-Y. Ku, C.-C. Chiu, H.-T. Chen, and S.-H. Hong, "Visual motorcycle detection and tracking algorithms," *WSEAS Transaction on electronics*, pp. 121-131, 2008.
- [4] J. F. Canny, "Finding edges and lines in images," *Massachusetts Inst. of Tech. Report*, vol. 1, 1983.
- [5] C.-Y. Wen, S.-H. Chiu, J.-J. Liaw, and C.-P. Lu, "The safety helmet detection for ATM's surveillance system via the modified Hough transform," in *Security Technology, 2003. Proceedings. IEEE 37th Annual 2003 International Carnahan Conference on*, 2003, pp. 364-369.
- [6] J. Chiverton, "Helmet presence classification with motorcycle detection and tracking," *Intelligent Transport Systems, IET*, vol. 6, pp. 259-269, 2012.
- [7] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, 2005, pp. 886-893.
- [8] C.-C. Chang and C.-J. Lin, "LIBSVM: a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, p. 27, 2011.

- 
- [9] R. Silva, K. Aires, T. Santos, K. Abdala, R. Veras, and A. Soares, "Automatic detection of motorcyclists without helmet," in *Computing Conference (CLEI), 2013 XXXIX Latin American*, 2013, pp. 1-7.
- [10] Z. Zivkovic, "Improved adaptive Gaussian mixture model for background subtraction," in *Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on*, 2004, pp. 28-31.
- [11] S. Du, M. Shehata, and W. Badawy, "Hard hat detection in video sequences based on face features, motion and color information," in *Computer Research and Development (ICCRD), 2011 3rd International Conference on*, 2011, pp. 25-29.
- [12] R. Waranusast, N. Bundon, V. Timtong, C. Tangnoi, and P. Pattanathaburt, "Machine vision techniques for motorcycle safety helmet detection," in *IVCNZ*, 2013, pp. 35-40.
- [13] T. Cover and P. Hart, "Nearest neighbor pattern classification," *Information Theory, IEEE Transactions on*, vol. 13, pp. 21-27, 1967.
- [14] M.-W. Park and I. Brilakis, "Construction worker detection in video frames for initializing vision trackers," *Automation in Construction*, vol. 28, pp. 15-25, 2012.
- [15] S. J. McKenna, S. Jabri, Z. Duric, A. Rosenfeld, and H. Wechsler, "Tracking groups of people," *Computer Vision and Image Understanding*, vol. 80, pp. 42-56, 2000.
- [16] R. M. Haralock and L. G. Shapiro, *Computer and robot vision*: Addison-Wesley Longman Publishing Co., Inc., 1991.
- [17] 楊佳穎, "以膚色資訊加速之 AdaBoost 即時人臉偵測系統," *臺灣大學工程科學及海洋工程學研究所學位論文*, pp. 1-64, 2011.
- [18] A. R. Smith, "Color gamut transform pairs," in *ACM SIGGRAPH Computer*

Graphics, 1978, pp. 12-19.

- [19] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern recognition*, vol. 29, pp. 51-59, 1996.
- [20] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 24, pp. 971-987, 2002.
- [21] C. Cortes and V. Vapnik, "Support-vector networks," *Machine learning*, vol. 20, pp. 273-297, 1995.
- [22] 支 持 向 量 機 ,
<http://zh.wikipedia.org/wiki/%E6%94%AF%E6%8C%81%E5%90%91%E9%87%8F%E6%9C%BA>.

附錄一




本附錄為以不同維度之 HS 直方圖特徵，安全帽之訓練結果。

SVM model	H 維度	S 維度	Precision	Recall	Accuracy
train_helmet_data_8_8	8	8	97.5728% (402/412)	95.9427% (402/419)	96.6708% (784/811)
train_helmet_data_8_16	8	16	94.8837% (408/430)	97.3747% (408/419)	95.9309% (778/811)
train_helmet_data_8_32	8	32	98.9975% (395/399)	94.2721% (395/419)	96.5475% (783/811)
train_helmet_data_8_64	8	64	98.5185% (399/405)	95.2267% (399/419)	96.7941% (785/811)
train_helmet_data_8_128	8	128	99.0172% (403/407)	96.1814% (403/419)	97.5339% (791/811)
train_helmet_data_8_256	8	256	99.5122% (408/410)	97.3747% (408/419)	98.397% (798/811)
train_helmet_data_16_8	16	8	98.7469% (394/399)	94.0334% (394/419)	96.3009% (781/811)
train_helmet_data_16_16	16	16	99.2593% (402/405)	95.9427% (402/419)	97.5339% (791/811)
train_helmet_data_16_32	16	32	99.505% (402/404)	95.9427% (402/419)	97.6572% (792/811)
train_helmet_data_16_64	16	64	99.0099% (402/404)	95.4654% (402/419)	97.164% (792/811)

			(400/404)	(400/419)	(788/811)
train_helmet_data_16_128	16	128	99.5074% (404/406)	96.42% (404/419)	97.9038% (794/811)
train_helmet_data_16_256	16	256	99.511% (407/409)	97.136% (407/419)	98.2737% (797/811)
train_helmet_data_32_8	32	8	98.7593% (398/403)	94.9881% (398/419)	96.7941% (785/811)
train_helmet_data_32_16	32	16	98.5366% (404/410)	96.42% (404/419)	97.4106% (790/811)
train_helmet_data_32_32	32	32	99.5062% (403/405)	96.1814% (403/419)	97.7805% (793/811)
train_helmet_data_32_64	32	64	99.0099% (400/404)	95.4654% (400/419)	97.164% (788/811)
train_helmet_data_32_128	32	128	99.2647% (405/408)	96.6587% (405/419)	97.9038% (794/811)
train_helmet_data_32_256	32	256	99.0244% (406/410)	96.8974% (406/419)	97.9038% (794/811)
train_helmet_data_64_8	64	8	99.511% (407/409)	97.136% (407/419)	98.2737% (797/811)
train_helmet_data_64_16	64	16	99.7537% (405/406)	96.6587% (405/419)	98.1504% (796/811)
train_helmet_data_64_32	64	32	99.5037% (401/403)	95.7041% (401/419)	97.5339% (791/811)

train_helmet_data_64_64	64	64	100% (403/403)	96.1814% (403/419)	98.0271% (795/811)
train_helmet_data_64_128	64	128	100% (404/404)	96.42% (404/419)	98.1504% (796/811)
train_helmet_data_64_256	64	256	99.7537% (405/406)	96.6587% (405/419)	98.1504% (796/811)
train_helmet_data_128_8	128	8	99.5086% (405/407)	96.6587% (405/419)	98.0271% (795/811)
train_helmet_data_128_16	128	16	99.7543% (406/407)	96.8974% (406/419)	98.2737% (797/811)
train_helmet_data_128_32	128	32	100% (407/407)	97.136% (407/419)	98.5203% (799/811)
train_helmet_data_128_64	128	64	100% (406/406)	96.8974% (406/419)	98.397% (798/811)
train_helmet_data_128_12 8	128	128	100% (404/404)	96.42% (404/419)	98.1504% (796/811)
train_helmet_data_128_25 6	128	256	100% (409/409)	97.6134% (409/419)	98.767% (801/811)
train_helmet_data_256_8	256	8	99.511% (407/409)	97.136% (407/419)	98.2737% (797/811)
train_helmet_data_256_16	256	16	99.7561% (409/410)	97.6134% (409/419)	98.6436% (800/811)
train_helmet_data_256_32	256	32	100%	97.136%	98.5203%



			(407/407)	(407/419)	(799/811)
train_helmet_data_256_64	256	64	100% (407/407)	97.136% (407/419)	98.5203% (799/811)
train_helmet_data_256_12 8	256	128	100% (403/403)	96.1814% (403/419)	98.0271% (795/811)
train_helmet_data_256_25 6	256	256	100% (409/409)	97.6134% (409/419)	98.767% (801/811)


附錄二




本附錄為以不同維度之 HS 直方圖特徵，安全背心之訓練結果。

SVM model	H 維度	S 維度	Precision	Recall	Accuracy
train_vest_data_8_8	8	8	95.7983% (114/119)	93.4426% (114/122)	95.5326% (278/291)
train_vest_data_8_16	8	16	95.0413% (115/121)	94.2623% (115/122)	95.5326% (278/291)
train_vest_data_8_32	8	32	93.4959% (115/123)	94.2623% (115/122)	94.8454% (276/291)
train_vest_data_8_64	8	64	95.122% (117/123)	95.9016% (117/122)	96.2199% (280/291)
train_vest_data_8_128	8	128	94.2149% (114/121)	93.4426% (114/122)	94.8454% (276/291)
train_vest_data_8_256	8	256	93.6% (117/125)	95.9016% (117/122)	95.5326% (278/291)
train_vest_data_16_8	16	8	93.4426% (114/122)	93.4426% (114/122)	94.5017% (275/291)
train_vest_data_16_16	16	16	94.1667% (113/120)	92.623% (113/122)	94.5017% (275/291)
train_vest_data_16_32	16	32	94.1667% (113/120)	92.623% (113/122)	94.5017% (275/291)
train_vest_data_16_64	16	64	94.3089%	95.082%	95.5326%

			(116/123)	(116/122)	(278/291)
train_vest_data_16_128	16	128	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_16_256	16	256	94.2623% (115/122)	94.2623% (115/122)	95.189% (277/291)
train_vest_data_32_8	32	8	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_32_16	32	16	95% (114/120)	93.4426% (114/122)	95.189% (277/291)
train_vest_data_32_32	32	32	95% (114/120)	93.4426% (114/122)	95.189% (277/291)
train_vest_data_32_64	32	64	94.3089% (116/123)	95.082% (116/122)	95.5326% (278/291)
train_vest_data_32_128	32	128	94.3089% (116/123)	95.082% (116/122)	95.5326% (278/291)
train_vest_data_32_256	32	256	93.5484% (116/124)	95.082% (116/122)	95.189% (277/291)
train_vest_data_64_8	64	8	95.8333% (115/120)	94.2623% (115/122)	95.8763% (279/291)
train_vest_data_64_16	64	16	96.5517% (112/116)	91.8033% (112/122)	95.189% (277/291)
train_vest_data_64_32	64	32	96.4912% (110/114)	90.1639% (110/122)	94.5017% (275/291)



train_vest_data_64_64	64	64	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_64_128	64	128	95.122% (117/123)	95.9016% (117/122)	96.2199% (280/291)
train_vest_data_64_256	64	256	93.5484% (116/124)	95.082% (116/122)	95.189% (277/291)
train_vest_data_128_8	128	8	97.3913% (112/115)	91.8033% (112/122)	95.5326% (278/291)
train_vest_data_128_16	128	16	96.6667% (116/120)	95.082% (116/122)	96.5636% (281/291)
train_vest_data_128_32	128	32	95.8678% (116/121)	95.082% (116/122)	96.2199% (280/291)
train_vest_data_128_64	128	64	95.9016% (117/122)	95.9016% (117/122)	96.5636% (281/291)
train_vest_data_128_128	128	128	96.6942% (117/121)	95.9016% (117/122)	96.9072% (282/291)
train_vest_data_128_256	128	256	93.6508% (118/126)	96.7213% (118/122)	95.8763% (279/291)
train_vest_data_256_8	256	8	97.4576% (115/118)	94.2623% (115/122)	96.5636% (281/291)
train_vest_data_256_16	256	16	97.479% (116/119)	95.082% (116/122)	96.9072% (282/291)
train_vest_data_256_32	256	32	96.6942% (116/119)	95.9016% (116/122)	96.9072%



			(117/121)	(117/122)	(282/291)
train_vest_data_256_64	256	64	96.6667% (116/120)	95.082% (116/122)	96.5636% (281/291)
train_vest_data_256_128	256	128	95.935% (118/123)	96.7213% (118/122)	96.9072% (282/291)
train_vest_data_256_256	256	256	94.4444% (119/126)	97.541% (119/122)	96.5636% (281/291)


附錄三




本附錄為以不同維度之 HS 直方圖結合 LBP 直方圖為特徵，安全帽之訓練結果。

SVM model	H 維度	S 維度	Precision	Recall	Accuracy
train_helmet_data_8_8_lb p	8	8	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_8_16_l bp	8	16	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_8_32_l bp	8	32	99.5204% (415/417)	99.0453% (415/419)	99.2602% (805/811)
train_helmet_data_8_64_l bp	8	64	99.759% (414/415)	98.8067% (414/419)	99.2602% (805/811)
train_helmet_data_8_128_ lbp	8	128	99.7608% (417/418)	99.5227% (417/419)	99.6301% (808/811)
train_helmet_data_8_256_ lbp	8	256	99.5227% (417/419)	99.5227% (417/419)	99.5068% (807/811)
train_helmet_data_16_8_l bp	16	8	99.7596% (415/416)	99.0453% (415/419)	99.3835% (806/811)
train_helmet_data_16_16_ lbp	16	16	99.7596% (415/416)	99.0453% (415/419)	99.3835% (806/811)
train_helmet_data_16_32_ lbp	16	32	99.7596% (415/416)	99.0453% (415/419)	99.3835% (806/811)
train_helmet_data_16_64_ lbp	16	64	99.7602% (415/416)	99.284% (415/419)	99.5068% (806/811)

lbp			(416/417)	(416/419)	(807/811)
train_helmet_data_16_128 _lbp	16	128	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_16_256 _lbp	16	256	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_32_8_1 bp	32	8	99.7596% (415/416)	99.0453% (415/419)	99.3835% (806/811)
train_helmet_data_32_16_ lbp	32	16	99.2806% (414/417)	98.8067% (414/419)	99.0136% (803/811)
train_helmet_data_32_32_ lbp	32	32	99.2788% (413/416)	98.568% (413/419)	98.8903% (802/811)
train_helmet_data_32_64_ lbp	32	64	99.7596% (415/416)	99.0453% (415/419)	99.3835% (806/811)
train_helmet_data_32_128 _lbp	32	128	99.7585% (413/414)	98.568% (413/419)	99.1369% (804/811)
train_helmet_data_32_256 _lbp	32	256	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_64_8_1 bp	64	8	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_64_16_ lbp	64	16	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_64_32_ lbp	64	32	99.2823% (415/418)	99.0453% (415/419)	99.1369% (804/811)



train_helmet_data_64_64_ lbp	64	64	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_64_128_ _lbp	64	128	99.7608% (417/418)	99.5227% (417/419)	99.6301% (808/811)
train_helmet_data_64_256_ _lbp	64	256	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_128_8_ lbp	128	8	99.759% (414/415)	98.8067% (414/419)	99.2602% (805/811)
train_helmet_data_128_16_ _lbp	128	16	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_128_32_ _lbp	128	32	99.7602% (416/417)	99.284% (416/419)	99.5068% (807/811)
train_helmet_data_128_64_ _lbp	128	64	99.284% (416/419)	99.284% (416/419)	99.2602% (805/811)
train_helmet_data_128_12_ 8_lbp	128	128	99.7608% (417/418)	99.5227% (417/419)	99.6301% (808/811)
train_helmet_data_128_25_ 6_lbp	128	256	99.0431% (414/418)	98.8067% (414/419)	98.8903% (802/811)
train_helmet_data_256_8_ lbp	256	8	99.7579% (412/413)	98.3294% (412/419)	99.0136% (803/811)
train_helmet_data_256_16_ _lbp	256	16	99.5204% (415/417)	99.0453% (415/419)	99.2602% (805/811)
train_helmet_data_256_32	256	32	99.5204%	99.0453%	99.2602%




_lbp			(415/417)	(415/419)	(805/811)
train_helmet_data_256_64 _lbp	256	64	99.0499% (417/421)	99.5227% (417/419)	99.2602% (805/811)
train_helmet_data_256_12 8_lbp	256	128	99.5227% (417/419)	99.5227% (417/419)	99.5068% (807/811)
train_helmet_data_256_25 6_lbp	256	256	99.5227% (417/419)	99.5227% (417/419)	99.5068% (807/811)

附錄四




本附錄為以不同維度之 HS 直方圖結合 LBP 直方圖為特徵，安全背心之訓練結果。

SVM model	H 維度	S 維度	Precision	Recall	Accuracy
train_vest_data_8_8_lbp	8	8	96.4602% (109/113)	89.3443% (109/122)	94.1581% (274/291)
train_vest_data_8_16_lbp	8	16	94.3089% (116/123)	95.082% (116/122)	95.5326% (278/291)
train_vest_data_8_32_lbp	8	32	95.122% (117/123)	95.9016% (117/122)	96.2199% (280/291)
train_vest_data_8_64_lbp	8	64	95.122% (117/123)	95.9016% (117/122)	96.2199% (280/291)
train_vest_data_8_128_lbp	8	128	96.6387% (115/119)	94.2623% (115/122)	96.2199% (280/291)
train_vest_data_8_256_lbp	8	256	93.6508% (118/126)	96.7213% (118/122)	95.8763% (279/291)
train_vest_data_16_8_lbp	16	8	95.9016% (117/122)	95.9016% (117/122)	96.5636% (281/291)
train_vest_data_16_16_lbp	16	16	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_16_32_lbp	16	32	95.8678% (116/121)	95.082% (116/122)	96.2199% (280/291)



train_vest_data_16_64_lbp	16	64	95.8678% (116/121)	95.082% (116/122)	96.2199% (280/291)
train_vest_data_16_128_lbp	16	128	95.8678% (116/121)	95.082% (116/122)	96.2199% (280/291)
train_vest_data_16_256_lbp	16	256	93.6% (117/125)	95.9016% (117/122)	95.5326% (278/291)
train_vest_data_32_8_lbp	32	8	95.0413% (115/121)	94.2623% (115/122)	95.5326% (278/291)
train_vest_data_32_16_lbp	32	16	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_32_32_lbp	32	32	96.6387% (115/119)	94.2623% (115/122)	96.2199% (280/291)
train_vest_data_32_64_lbp	32	64	95.8678% (116/121)	95.082% (116/122)	96.2199% (280/291)
train_vest_data_32_128_lbp	32	128	95% (114/120)	93.4426% (114/122)	95.189% (277/291)
train_vest_data_32_256_lbp	32	256	94.3548% (117/124)	95.9016% (117/122)	95.8763% (279/291)
train_vest_data_64_8_lbp	64	8	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_64_16_lbp	64	16	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_64_32_lbp	64	32	96.6667% (116/122)	95.082% (116/122)	96.5636% (280/291)

			(116/120)	(116/122)	(281/291)
train_vest_data_64_64_lbp	64	64	95.082% (116/122)	95.082% (116/122)	95.8763% (279/291)
train_vest_data_64_128_lbp	64	128	92.6829% (114/123)	93.4426% (114/122)/	94.1581% (274/291)
train_vest_data_64_256_lbp	64	256	92.8571% (117/126)	95.9016% (117/122)	95.189% (277/291)
train_vest_data_128_8_lbp	128	8	100% (115/115)	94.2623% (115/122)	97.5945% (284/291)
train_vest_data_128_16_lbp	128	16	99.1379% (115/116)	94.2623% (115/122)	97.2509% (283/291)
train_vest_data_128_32_lbp	128	32	97.4138% (113/116)	92.623% (113/122)	95.8763% (279/291)
train_vest_data_128_64_lbp	128	64	98.2906% (115/117)	94.2623% (115/122)	96.9072% (282/291)
train_vest_data_128_128_lbp	128	128	96.7213% (118/122)	96.7213% (118/122)	97.2509% (283/291)
train_vest_data_128_256_lbp	128	256	95.122% (117/123)	95.9016% (117/122)	96.2199% (280/291)
train_vest_data_256_8_lbp	256	8	99.1304% (114/115)	93.4426% (114/122)	96.9072% (282/291)
train_vest_data_256_16_lbp	256	16	99.1304% (114/115)	93.4426% (114/122)	96.9072% (282/291)



train_vest_data_256_32_lbp	256	32	99.1228% (113/114)	92.623% (113/122)	96.5636% (281/291)
train_vest_data_256_64_lbp	256	64	98.2906% (115/117)	94.2623% (115/122)	96.9072% (282/291)
train_vest_data_256_128_lbp	256	128	95.935% (118/123)	96.7213% (118/122)	96.9072% (282/291)
train_vest_data_256_256_lbp	256	256	95.1613% (118/124)	96.7213% (118/122)	96.5636% (281/291)