

第五章 概念分析器 (conceptual analyzer)

由知覺分析器所得到的特徵向量，傳送至概念分析器以作出分類的依據。概念分析器主要分為兩個模組，一為 CART(configurable adaptive resonance theory) 類神經網路模組；另一為決策(decision making)模組。前者依據輸入的特徵向量作出分類的結果，後者則將多組分類結果作整合。

5.1 CART (configurable adaptive resonance theory) 類神經網路模組

CART (configurable adaptive resonance theory) 類神經網路其實就是 ART2 類神經網路的改良版。當特徵向量輸入 ART2 類神經網路後，ART2 會對輸入的特徵向量做分類，此一輸入的特徵向量將與系統中在長期記憶裏事先儲存完整訊息進行分類比對。若比對成功，則輸出比對結果。但若長期記憶中儲存的特徵向量與實際從影像中擷取出的特徵向量在比對時仍有些微差異，那麼可以利用 supervised learning 的方式稍微調整長期記憶的內容以符合目前外在環境的改變。反之，若辨識失敗，表示系統面臨了某類尚未學習過的新物件，系統將利用 unsupervised learning 的方式將學習新物件類別並儲存於長期記憶中。當長期記憶學習並記錄了此一新的類別，則會使得再次比對的結果轉為成功並輸出此新的類別。上述機制非常適合用 Carpenter 以及 Grossberg 所提出的 ART2 [Gar91]來實現。

由於人類的神經元數目有限，但卻可以做種類極為龐大的工作。以人類辨識的過程來說，當有外界的訊息刺激人類的感官時，大腦會將部份神經元組成一神經網路來作辨識的工作，一旦辨識完成，便將這些神經元釋放以便支援其他的工作。這樣一來，我們便可以重複利用有限的神經元作許多的工作。而在本研究中，CART 類神經網路的“C”所代表的是“configurable”的意思，主要是在模擬上述人類神經網路的功能。

在第四章之圖 4-6 中，定義了單一鄰近車輛與本車動向之注意力圖像。這些注意力圖像可以先作為 CART 類神經網路之 training data，如此一旦有類似的狀況發生時就很容易被辨識出來。在考慮複雜情況時，我們也可以讓 CART 類神經網路事先學習這些複雜情況，以得到分類結果。但是這樣複雜情況的組合實在太

多了，加上各個事件出現的順序不一定，未必可以讓 CART 類神經網路學習到所有可能的狀況，況且這樣的工程也未免太大了。而且車輛可能會在任何一個地方出現，如果直接將整張注意力圖像輸入 CART 類神經網路辨識，則同樣的狀況可能會因為出現位置些許不同而辨識成不同的狀況。況且，如果輸入 CART 類神經網路 training 的各個樣式的差異度不夠大，便會對此類神經網路造成干擾，導致分類的錯誤。因此我們才會先分割注意力圖像，以便可以在不同視窗中辨識出不同的狀況。並藉由各個視窗辨識結果來整合出一組可能的狀況。

由於先前找定性特徵時，我們將注意力圖像分割成五個視窗，因此針對每個視窗便需要一個 CART 類神經網路來進行分類的工作。在知覺分析器中所得到的定性特徵之特徵向量具有正值與負值（正偏態與負偏態），然而 CART 類神經網路只能處理正值的特徵向量，可利用下列公式將之前所得到的定性特徵之特徵向量轉換成正值。

$$f'_{w_n} = \left(\frac{f_{w_n}^m}{T} + 1 \right) / 2, \quad (5-1)$$


其中 $T = \sum_{m=1}^{20} f_{w_n}^m$ ， $n = 1, 2, \dots, 5$ 。

以第四章之圖 4-11 與圖 4-12 為例，利用式(5-1)可得到新的偏態值如表 5-1。圖 5-1(a)為轉換前之特徵向量元素分布圖；圖 5-1(b)為轉換後之特徵向量元素分布圖。由圖中可以發現特徵向量分布的曲線輪廓在轉換前後並無改變，改變的只是特徵向量的範圍而已。


表 5-1、圖 4-11 與圖 4-12 之偏態值轉換。

m 值	原本的偏態值	轉換後的偏態值
1	0.0000	0.5000
2	0.0000	0.5000
3	0.1985	0.5014
4	3.7861	0.5258
5	10.3928	0.5709
6	13.5846	0.5927
7	13.2387	0.5904
8	12.0544	0.5823
9	10.6915	0.5730
10	9.2949	0.5635
11	-14.1868	0.3603
12	-15.0058	0.3523
13	-13.2176	0.3699
14	-4.5739	0.4550
15	2.5523	0.5251
16	1.2520	0.5123
17	0.0000	0.5000
18	0.0000	0.5000
19	0.0000	0.5000
20	0.0000	0.5000

由前面曾經提到將轉換過後的特徵向量輸入 CART 類神經網路後可以得到分類結果。或許在某個視窗中無法分辨出某些注意力圖像的類別，但是這些圖像可能可以在其他的視窗中被分辨出來。另外，有些注意力圖像在某些視窗中所呈現的漸層分布可能相當類似，也就是特徵雷同，但是在其他的視窗中所呈現的漸層分布就不一定會雷同。這些情況都是為什麼要利用多個視窗分割的原因。有時候某個 CART 類神經網路會因為輸入該類神經網路的特徵資訊不足，可能會做出錯誤的分類，這樣的狀況本系統是可以容忍的，因為系統可以利用其他 CART 類神經網路的輸出來做修正，以便獲得較正確的分類結果。因此本論文中設計了一個機制來整合各個 CART 類神經網路之分類結果，以提供一個正確的鄰近車輛動向來提醒駕駛者注意。



(a)



(b)

圖 5-1、特徵向量轉換前後之折線圖：(a)轉換前，(b)轉換後。

5.2 決策 (decision making) 模組

系統將得到的注意力圖像分割成五個視窗，再分別利用五個 CART 類神經網路作分類的工作。由於每個分類結果不一定會相同，因此五個 CART 類神經網路之分類結果便要整合以便輸出最後的決定。在整合分類結果時，本研究所利用的方法是改良後的 fuzzy integral 技術。

由於系統所接受的輸入為一序列的注意力圖像，經由視窗分割後，將會得到五個分割後的注意力圖像；每個分割後的注意力圖像則會經由個別的 CART 類神經網路得到一序列的分類結果，如圖 5-2 所示。假設注意力圖像在時間 $t-r_i+1$ 開始形成，則我們將此時間定義為一個動作之開始。系統會針對每個 CART 類神經網路的序列，輸出在每一個時間點上所整合的分類結果，分別以 d'_1, d'_2, \dots, d'_n 表示。最後再將這些結果整合起來以便得到最後的分類結果 (\mathbf{D}')。在這裡 \mathbf{D}' 可能為單一狀況或者多種狀況。

令 $s_i^{t-r_i+1} s_i^{t-r_i+2} \dots s_i^t$ 表示 CART_i 類神經網路在時間 $t-r_i$ 至時間 t 中所輸出的一序列分類結果，其中 r_i 代表某一動作開始發生至目前所花之時間。令 $L = \{l^0, l^1, \dots, l^r\}$ 代表 CART_i 類神經網路所能夠辨識的標記集合，其中包含空標記 l^0 ，每個標記 l^k 分別對應至事先所存好的鄰近車輛之危險動向類別樣式 p^k 。每個由 CART_i 類神經網路所輸出的分類結果皆會對應到此集合 L ，也就是說 $s_i^{t-r_i+j} \in L$ ， $j = 1, 2, 3, \dots, r_i$ 。

令 $h(\cdot)$ 與 $g(\cdot)$ 分別表示 fuzzy integral 中的信心函數 (confidence function) 與模糊計量函數 (fuzzy measure function)。信心函數 $h: L \rightarrow [0, 1]$ 定義於集合 L 上；而模糊計量函數 $g: 2^L \rightarrow [0, 1]$ 定義於集合 L 的冪集合 (power set) 上。模糊計量函數 $g(\cdot)$ 有多種選擇方法，但是無論選擇哪一種方法，都必須符合以下的特性：

- (1). $g(\emptyset) = 0$ 且 $g(L) = 1$ 。(boundary property)
- (2). 當 $B \supseteq A$ 時， $\forall A, B \in 2^L$ ， $g(B) \geq g(A)$ 。(monotonicity property)
- (3). 如果 $A_1 \subset A_2 \subset \dots$ ，則 $\lim_{i \rightarrow \infty} g(A_i) = g(\bigcup_{i=1}^{\infty} A_i)$ 。(continuity property)

(4). 如果 $A_1 \supset A_2 \supset \dots$, 則 $\lim_{i \rightarrow \infty} g(A_i) = g(\bigcap_{i=1}^{\infty} A_i)$. (continuity property)

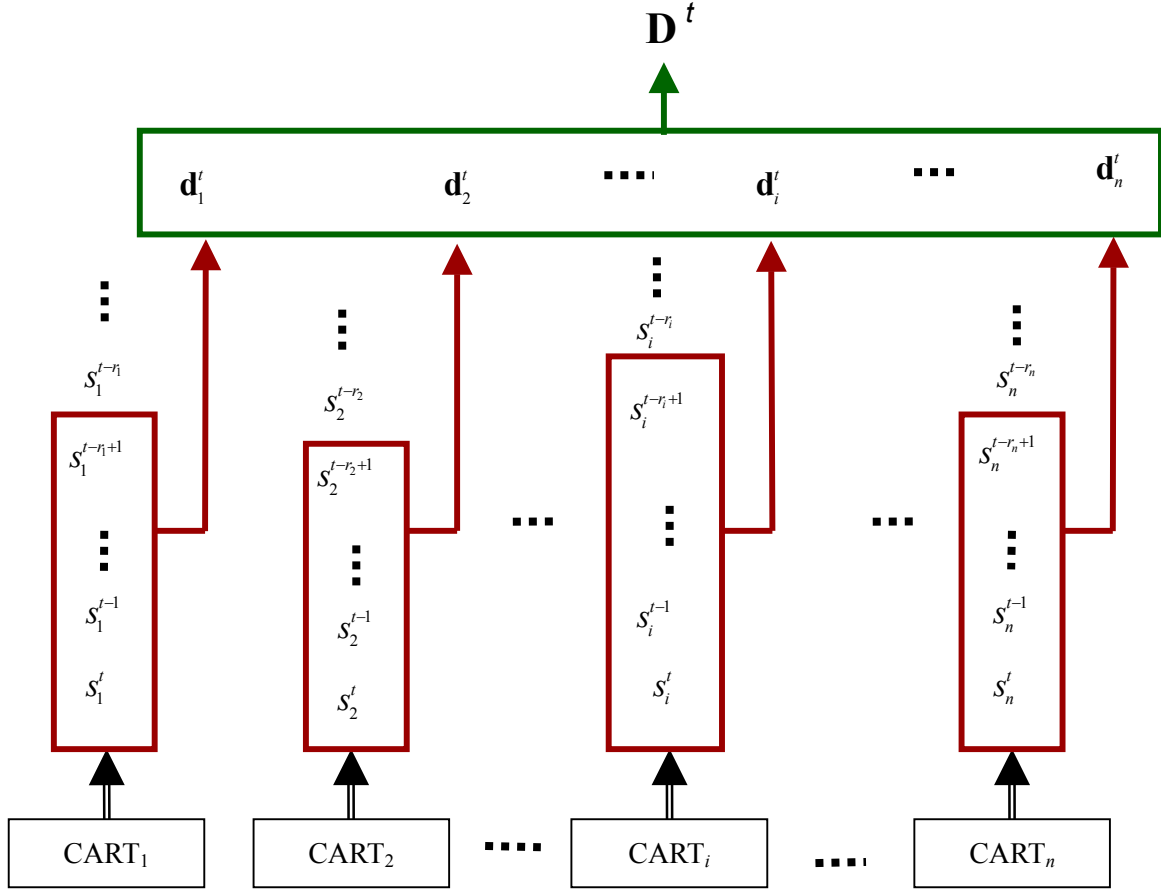


圖 5-2、整合個別 CART 類神經網路的分類結果之流程圖。紅色方框代表針對個別 CART 類神經網路整合某段時間之分類結果；綠色方框代表整合每個紅色方框整合後之結果。

5.2.1 信心函數 (confidence function)

對於不同的應用，信心函數與模糊計量函數的定義也不盡相同。在本應用中，針對 $CART_i$ 類神經網路在時間 $t - r_i + j$ 的分類結果 $s_i^{t-r_i+j}$ 之信心函數，定義如下：

$$h^{t-r_i+j}(s_i^{t-r_i+j}) = \begin{cases} w(j, k) & \text{if } l^j = l^k \\ \frac{w'(j, k)}{\|p^j - p^k\|_2} & \text{otherwise} \end{cases} ,$$

其中 $w(j, k) = \frac{1}{1 + e^{-\alpha|r_i-j||r_i-k|}}$, $w'(j, k) = \frac{1}{1 + e^{-\beta|r_i-j||r_i-k|}}$. p^j 與 p^k 分別為標記 l^j

與標記 l^k 所對應之事先存好的鄰近車輛之危險動向樣式。 $\|p^j - p^k\|$ 代表樣式 p^j 與樣式 p^k 的差異值。 $l^j, l^k \in L$ ，其中 $j, k = 1, 2, 3, \dots, r_i$ 。 α 與 β 為指定變數。

信心函數主要處理時間上的整合結果。當別人與自己的決定相同時，且兩者時間差越小者，則信心值越高。

5.2.2 模糊計量函數 (fuzzy measure function)

針對 $CART_i$ 類神經網路在時間 $t - r_i + j$ 分類結果 $s_i^{t-r_i+j}$ 之模糊計量函數，定義如下：

$$g^{t-r_i+j}(s_i^{t-r_i+j}) = \min\left\{\frac{r1}{r2}, \frac{r2}{r1}\right\},$$

其中 $r1$ 代表輸入的注意力圖像在視窗 i 中亮點之於視窗面積的比例， $r2$ 代表分類結果 $s_i^{t-r_i+j}$ 所對應資料庫中鄰近車輛之危險動向樣式在視窗 i 中亮點之於視窗面積的比例。

5.2.3 模糊整合 (fuzzy integral)

對於分類結果 $s_i^{t-r_i+j}$ 的整合值定義如下：

$$e^{s_i^{t-r_i+j}} = \int h^{s_i^{t-r_i+j}}(s) \circ g = \sup_{\alpha \in [0,1]} \{\alpha \wedge g(F_\alpha)\},$$

其中 \wedge 代表具有 t-norm 特徵的模糊交集 (fuzzy intersection)， $F_\alpha = \{s \mid h^{s_i^{t-r_i+j}}(s) \geq \alpha\}$ 。

$CART_i$ 類神經網路的中間決策集合 \mathbf{d}_i^t (intermediate decision set) 之元素為最大整合值或與最大整合值相差小於 Γ 之標記，定義如下：

$$\mathbf{d}_i^t = \left\{ l_i^s \mid \text{the corresponding label of } \arg(e^s \mid |e^s - e^{\max}| \leq \Gamma) \right\},$$

其中 $e^{\max} = \max_{j=1, \dots, r_i} \{e^{s_i^{t-r_i+j}}\}$ ， Γ 為門檻值。集合 \mathbf{d}_i^t 包括那些由 $CART_i$ 類神經網路所決定可能的鄰近車輛之危險動向類別。 $CART$ 類神經網路能夠針對輸入的注意力圖像正確地分類出結果，所以此集合通常只會有一個候選者。但是在資訊不足的情況下， $CART$ 類神經網路無法確定為何種樣式，如此就可能會有多个候選者。此時，就需要利用其他 $CART$ 類神經網路的分類結果來輔助以整合出最後的分類

結果。

假設 $CART_i$ 類神經網路的中間決策集合包含 m_i 個元素，即代表 $\mathbf{d}^i = \{l_1^i, l_2^i, \dots, l_{m_i}^i\}$ 而 l_j^i 表示 $CART_i$ 類神經網路的輸出標記，其中 $i=1, 2, 3, \dots, n$ ， $j=1, 2, 3, \dots, m_i$ 。因此我們可將中間決策集合整合為最後決策集合 $D' = \{d_1^i, d_2^i, \dots, d_n^i\}$ ，其定義如下：

$$\mathbf{D}' = \{l \mid l = \arg(f(l')) \text{ where } f(l') > \Gamma', \text{ for all } l' \in L\},$$

其中 $f(l') = \bigvee_{\substack{i=1, 2, \dots, n; \\ j=1, 2, \dots, m_i}} (\delta(l', l_j^i) e_j^i)$ ， $l_j^i \in \mathbf{d}_i^i$ ， e_j^i 為其 l_j^i 所對應之整合值。函數

$$\delta(l', l'') = \begin{cases} 1 & \text{if } l' = l'' \\ 0 & \text{otherwise} \end{cases},$$

其中 Γ' 為門檻值。最後決策集合即為我們所要輸出以提醒駕駛者注意的鄰近車輛之危險動向狀況，可能為單一或多種狀況。