以行動區域為基礎的垂直換手預測

張英超
彰化師範大學資訊工程學系
icchang@cc.ncue.edu.tw

王慶祥
台中縣永隆國小
shang@yles.tcc.edu.tw

連晨宇
彰化師範大學資訊工程學系
s91610044@mail.ncue.edu.tw

Abstract

本論文將提出的一個以區域(Area)為基礎的垂直行動預測(Vertical Motion Estimation, VME)的演算法，利用換手的歷史資料來訓練倒傳遞(Back Propagation Network, BPN)類神經網路，以取得 MN 的移動模式(mobility pattern)，將能有效且準確預測行動裝置(Mobile Node, MN)可能進入異質性環境下哪些目標無線網路(target networks)中的哪些目標蜂巢(target cells)。透過 IBM City Simulator 產生城市的架構，本論文將藉由模擬實驗證明這種以區域為基礎的垂直行動預測能夠達到與傳統同質性網路預測更好的預測準確度。

1. 簡介

未來的行動通訊系統將由各種不同類型的異質性(heterogeneous)的無線網路所組成，MN 將具備連接多種網路的能力，能依現況進行不同網路間的切換[1]，以便達成最佳化的通訊需求。相較於同質性無線網路的換手，在異質性的環境之下，網路將由許多大小不同且網路架構互異的細胞所組成，如圖一所示。依其訊號含蓋範圍與特性，大致可分成 Macro-Cells、Micro-Cells 和 Pico-Cells，其中 Macro-Cells 適合大範圍內移動速率高而通訊頻寬需求較低的傳輸，如 GPRS 或 3G 等廣域型無線網路(Wireless WAN, WWAN)；Micro-Cells 則適合室內移動速率不高但通訊頻寬需求較高的傳輸，如 IEEE802.11a/b 等區域型無線網路(WLAN)；至於 Pico-Cells 如藍芽，將提供電子產品的周邊通訊。在同質性網路下，換手只會發生在兩個細胞相鄰近之處，因此經由訊號強弱的偵測，便能掌握換手的可能性。但在上述異質無線網路的環境下，細胞間的訊號覆蓋區域不再只是局部的交集，小的 micro-cell 可能會被大的 macro-cell 完全包含，對於 macro-cell 而言，換手發生的地點將不再侷限於細胞之間的邊界地帶，這種異質性無線網路間的換手動作稱為垂直換手(vertical handoff)。

為了維持多媒體影音視訊的品質(Quality of Service, QoS)的需求，在[2]中，Hwang 等作者以 Direction-Based 對 MN 進行移動方向的預測; Misic 等提出了以 event-based 預測的方法[3]，參考 MN 的地理位置來觸發資源需求的判斷，由 MN 的移動方向和特定的角度，找出可能發生換手的細胞的作法，可發現越靠近換手邊界時，目標細胞選取的範圍也就減少許多。另外一類的研究則根據使用者移動模式的理論，以 MN 目前所處的地理位置、移動速度和方向能提供一些有用的資訊，做為預測目標細胞的參考。Soh 等利用 Global Positioning System (GPS)，掌握 MN 所在的位置做為換手預測的依據[4]。Yu 等經由取得 MN 的座標位置、移動速度和方向等重要特徵，作為類神經網路的輸入值，並以最後進入的細胞為輸出值，採用監督式的倒傳(Back Propagation Neural Networks)進行訓練，最後再利用已收斂的類神經網路來計算 MN 離開目前的細胞同時進入到特定細胞的可能性 [5]。但是以上的這些方法，都是以傳統同質性無線網路中的 MN 來探討，對於異質性環境並無法完全適用。其中最明顯的情況就是細胞間的實體拓樸將不再是蜂巢狀架構，一個 macro-cell 中可能包含數個 micro-cells，使得垂直換手不只是發生於細胞的邊界，也可能會產生在細胞中的任何位置。

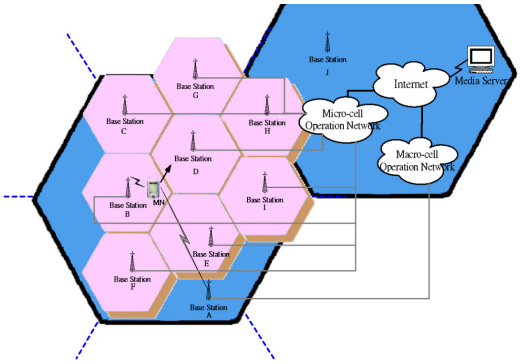

圖一、異質性無線網路的架構

本論文將利用本論文所提出的一個以區域(Area)為基礎的垂直行動預測(Vertical Motion Estimation, VME)的演算法，藉由 MN 偵測臨近異質性無線網路的訊號，得知有哪些基地台可以提供垂直換手連線的資源，歸納為目前細胞的資源地圖(resource map)，並利用換手的歷史資料來訓練倒傳遞(Back Propagation Network, BPN)類神經網路，以取得 MN 的移動模式(mobility

pattern)，能有效且準確預測 MN 可能進入異質性環境下的目標無線網路(target networks)中的目標細胞(target cells)，以進行資源預留等工作。在第二節中將詳細說明本論文所提出的以區域為基礎的垂直行動預測的演算法。有關模擬實驗的環境、參數和結果於第三節中詳述，最後則是本論文的結論。

2. 區域為基礎的垂直換手預測

為了進行垂直性移動預測(Vertical Motion Estimation, VME)，支援 MN 在垂直換手過程中對於多媒體 QoS 的確保，第一步利用 MN 接收到鄰近基地台導頻碼(Beacon code)時的位置，以瞭解位於目前細胞鄰近有那些可進行垂直換手的無線基地台，再透過統計的方式分別建立外在資源地圖(External Resource Map)和內在資源地圖(Internal Resource Map)。前者記錄位於目前所在基地台邊界上，所有可能無線網路上可進行垂直換手的細胞;後者是記錄 MN 為獲得更好 QoS 或更低的通訊成本，而在目前基地台內進行垂直換手的所有可能無線網路中的細胞。如此將能把實體拓樸中訊號範圍大小不一的異質性無線網路，產生所有無線網路各蜂巢基地台位置和訊號重疊分佈範圍。在圖二中，細胞 1, 4, 6, 7, 8, 9 與細胞 0 是同質的 Macro-cell 無線網路，而細胞 2, 3, 5 則是位於細胞 0 鄰近的異質性 Micro-cell。經由導頻碼所得的歷史記錄為將整理為(Net_i, $Cell_j$, $\theta_{min}(Cell_j)$, $\theta_{max}(Cell_j)$)，表示 MN 聆聽到其它基地台的導頻碼時，對方的網路類別代號 Net_i、基地台編號 $Cell_j$。鄰近細胞的分佈範圍則用接收到這個細胞導頻碼與目前細胞 0 的最小與最大夾角 $\theta_{min}(Cell_j)$ 和 $\theta_{max}(Cell_j)$ 來表示。

第二步將利用類神經網路進行垂直行動預測，目前細胞會對特定時間週期下，成功完成垂直換手的歷史資料進行記錄，其中包含觸發換手程序時 MN 的位置資訊，和完成換手結束舊有連線時的位置。透過 BPN 類神經網路的訓練學習，以掌握 MN 的地理位置資訊和移動至特定區域的可能性。使用細胞邊界附近的預先啟動的範圍(Pro-active region)作為觸發垂直行動預測的條件，當 MN 進入到此區域後，便會根據 MN 目前的移動方向、速度和資源地圖中細胞的分佈資訊，找出可能的目標細胞。由於篇幅所限，本論文以探討如何進行垂直行動預測做為重點。

2.1 換手區域的劃分

在本論文所提出的 VME，會從基地台的圓心採特定角度 θ ，將目前細胞區分為數個扇形區域，而在 PR 的邊界外產生換手區域 (handoff area)，分別用區域 1 至區域 N 來代表，而從目前基地台到 R_{out} 的範圍則視為區域 0，每一個區域其中可能會包含數個鄰近細胞。而一個 macro-cell 也有可能隸屬於數個區域之中。各個區域畫分的角度，將依據目前基地台與 PR 的距離 R_{out} 、所支援 MN 的最大移動速度 $\overline{V}$ 與偵測換手時間週期 τ 來決定，如圖三與公式(1)所示。所有區域的個數以公式(2)表示。

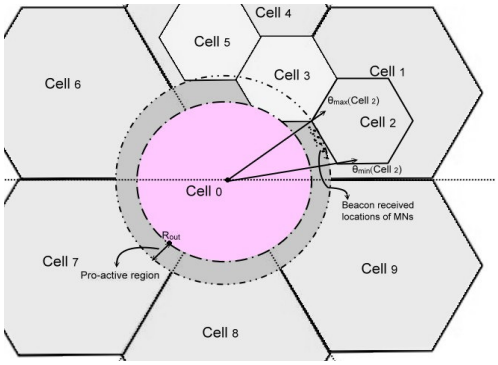

圖二、外在資源地圖

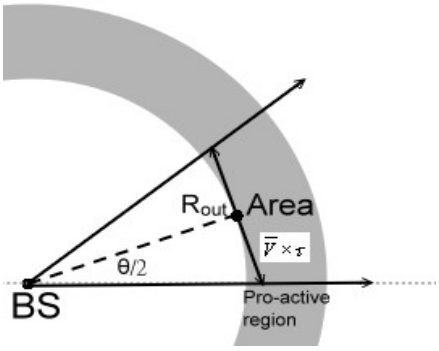

圖三、利用角度來畫分區域

$$\theta = 2 \times ATan(\frac{\overline{V} \times \tau}{R_{out}}) \quad (1)$$

$$\text{區域個數(N)} = 360° / \theta \quad (2)$$

之後每個區域會依設定範圍與外在資源地圖進行參照，以產生各個區域內包含那些細胞的對照表。在圖四中，目前細胞的外在資源地圖中包含了 Cell 1~5，而內部資源地圖則包含了 ICell 1~3、Cell 3。如何將外部 cell 歸納到每個區域所包含的外部資源之演算法則如圖五所示。

2.2 預先啟動的範圍

為了減少目標細胞的數量，同時提高預測的準確度，每一個細胞都將靠近細胞邊界上設定預先啟動的 PR 範圍，當 MN 進入到該區域之

後，才會觸發垂直行動預測的動作。該 PR 區域的範圍，用公式(3)與(4)表示如下：

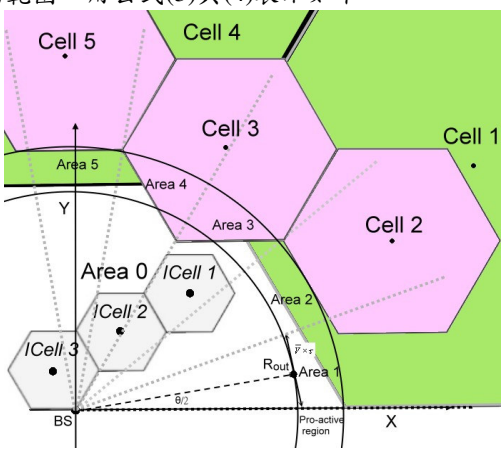

圖四、利用換手區域進行資源的歸類

```
for (i=1; i<=N; i++){//each External handoff Area i
    for each External cell j{
        if ( θmax(Area_i) ≥ θmin(Cell_j)  and
             θmax(Cell_j) ≥ θmin(Area_i) ) //overlapped!
            add Cell_j into Area_i ;
    }
}
```

圖五、將外部資源歸屬到鄰近區域的演算流程

$$D^i_{Pro-active} = max(\overline{V} \times \tau, R^i \times \delta^i), \quad 0 \le \delta \le 1 \quad (3)$$

$$R^i_{out} = R^i \times (1 - \delta^i) \quad (4)$$

其中 $D^i_{Pro-active}$ 代表 $Cell_i$ 中 PR 範圍的寬度。由於每一種無線網路的細胞訊號範圍大小不同，對於 MN 移動速度的支援狀況也不相同，因此以 MN 的最大可能移動速度 $\overline{V}$ 和基地台監控 MN 換手狀況的時間週期 τ 的乘積，或是與目前 $Cell_i$ 中預設的 PR 佔最大通訊距離的比例值 δ^i 與 $Cell_i$ 半徑 R^i 的乘積，兩者相較取其較大值作為 PR 範圍的大小，而公式 4 中的 R^i_{out} 是由目前基地台到它的 PR 範圍的距離。

2.3 BPN 類神經網路的預測

為了提高垂直行動預測的準確性，就必須對 MN 歷史的垂直換手記錄進行分析，從中找出移動模式。當 MN 進入 PR 範圍後，基地台會每隔一段週期時間 τ 偵察並記錄 MN 的位置和移動特性，直到發生垂直換手為止。這些歷史資料將以表格的方式記錄於目前基地台，其中將包含 MN 發生垂直換手時的區域，以及前一個時間週期 MN 與基地台的距離 D_{MN}、方向角度 θ_{MN}、移動速度 V_{MN}、移動方向 $\theta_{V(m)}$ 等。VME 採用倒傳遞(Back Propagation Network)的類神經網路，如圖六所示，在該模型中將包含三層式架構，分別為輸入(Input)、輸出(Output)和隱藏層(Hidden Layer)，並以歷史外在換手記錄表中，發生垂直換手的前一個時間週期 τ 值 MN 所在的地理位置(與基地台的距離 D_{MN} 和角度 θ_{MN})及 MN 移動情形(單位時間的移動距離 V_{MN} 和方向 $\theta_{V(m)}$)為輸入值，同時把 MN 所可能進入的區域當作期望輸出值。隱藏層在此的目的是為了對複雜移動樣式進行細部的辨認，所以設計採用 10x10 個 node 的雙隱藏層。

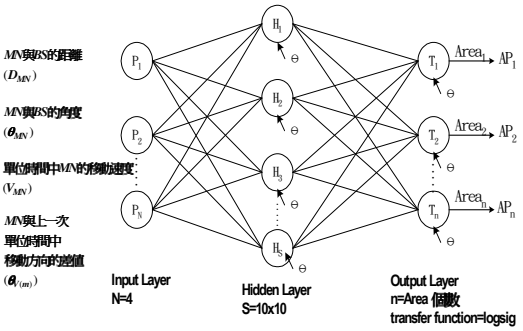

圖六、VME 採用的 BPN 類神經網路架構圖

2.4 目標細胞的選取

為了增加系統的利用率(utilization)，因此將依 MN 的位置和移動方向和速度來進行目標細胞的挑選，並依可能發生垂直換手的位置，區分為內在目標細胞(Internal target cell)和外在目標細胞(External target cell)兩類。由於內在目標細胞選擇是由於當 MN 所在的基地台無法提供所需的應用層服務，試圖尋找更好的 QoS 或更低費用的內在目標細胞時，便會觸發內在目標細胞的流程，與傳統同質性網路因更換基地台所發生的外在目標細胞選擇不同，因此本論文只討論所提出以區域為基礎的外在目標細胞選擇方法。內在目標細胞選擇方式請參考[6]。

當 MN 進入到 PR 範圍內，則 MN 的地理位置(與基地台的距離 D_{MN} 和角度 θ_{MN})及移動特性(單位時間的移動距離 V_{MN} 和方向 $\theta_{V(m)}$)將做為推論引擎的輸入值，並對於每個換手區域 n 獲得不同的輸出向量。經正規化後的向量值(AP_n)，將依照下圖七的外在目標細胞選擇演算法，達到系統所定的門檻值(threshold)的區域，將被 VME 視為目標區域。根據所設定的門檻值，可能同時會產生一個以上的目標區域，由於

每個目標區域各自包含許多細胞，在去除重覆的部份後，這些細胞將被視為外在目標細胞。

```
if ( D_MN > R^i_Out ){ //進入 Pro-active region
    for each handoff Area n {
        AP_n is the normalized BPN output
            value for Area n;
        if ( AP_n > threshold T) {
            for each external cell i in this Area
                select cell i it as an external
                target cell;
        }
    }
}
drop redundant external target cells;
```

圖七、外在目標細胞選擇的流程

3. 實驗

3.1 實驗環境與設計

在行動用戶的移動資料上，是透過 IBM alphaWorks 所提出的 City Simulator [7]來取得，可以利用所提供的屬性值，對於 MN 的移動速度、MN 個數進行設定。本實驗規劃以 6000 *6000 平方公尺做為基地台建置的區域，細胞排列的模式採 mesh-grid 的結構，其中有 9 個 macro-cell，以及 25 個 micro-cell，大的虛線圓圈代表著 macro-cell 的訊號作用範圍，而小的實心圓圈則代表 micro-cell 的作用區域。macro-cell 基地台的訊號作用直徑範圍設定為 1600 公尺，並與其它網路相鄰成六邊形細胞狀結構。而 micro-cell 的訊號作用直徑範圍為 800 公尺，同樣成為六邊形的細胞結構。其中所包括的道路及各項建築物的位置，如圖八所示，左半部為道路所分割出的區塊，區塊上有建築物，中央黑色部分為河流，右半部為草地。圖上的小點為 MN 所在位置。圖九為細胞與實際環境的分佈圖。

本實驗利用 City Simulator 產生不同筆數的樣本(5000, 10000, 20000)，每個樣本執行 100 個 cycle，記錄每一次 cycle 時 MN 的 timestamp、座標位置，再將此數值轉換成與基地台的距離、水平方位角度、速度和移動偏移的角度，做為類神經的輸入，而最後所進入的 cell/area 將視為輸出。其中某個比例(10%, 40%, 70%, 100%)的樣本將用訓練類神經網路，其他的比例(90%, 60%, 30%, 100%)做為測試類神經網路執行 VME 準確度的依據，觀察不同訓練比例對於準確度的影響，但是 100% 那次比例則是把全部的模擬用數據拿來訓練也拿來做為預測，作為準確度比較的基礎。Area-based 方式分別畫分為 6/12/18 個區域。實驗過程中所採用的參數如表一所示。

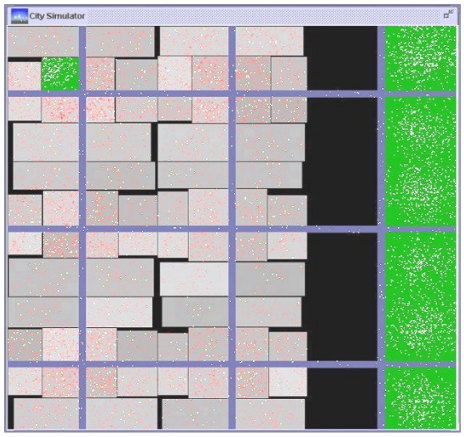

圖八、City Simulator 的操作畫面

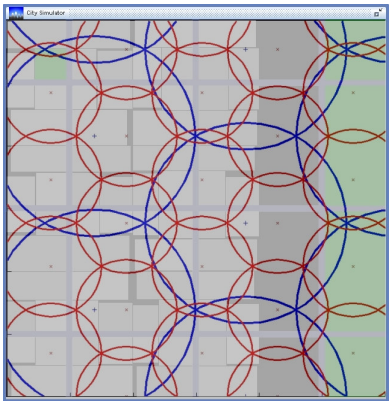

圖九、細胞分佈圖

實驗參數	預設值
速度與方向變動週期	τ =5 sec
MN 移動速度初始值	Normal distribution, mean 2 km/h, variance 1(km/h)^2
MN 移動速度變動值	Uniform distribution dV=[-0.5, 0.5]km/h
MN 移動方向初始值	Uniform distribution Q=[-π, π]
MN 移動方向變動值	Uniform distribution dQ=[-0.2π, 0.2π]
每一連線持續時間	Normal distribution, mean 600 sec, variance 200

表一、實驗參數

以下我們將比較使用兩類方式執行 VME 的準確度。在使用某種比例的 MN 行動記錄作為類神經網路的訓練過程中，為了提高預測的準確度，我們先在所有的移動紀錄資料中找出會換手的 MN，根據這些會做換手的 MN 的移動紀錄從要換手離開的那一筆資料往前尋找數筆移動

軌跡的資料，再將這些軌跡資料與 MN 的位置紀錄下來是屬於哪一個 cell 所擁有。若是當中有某一 MN 的位置分別被兩個以上的 cell 所同時覆蓋，則我們會根據亂數平均分配此一 node 要歸類哪一個 cell 所擁有。若採用 area-based 的方式，將進一步歸納此 cell 到所屬的 area。接下來依照訓練比例，由每個 cell (cell-based)或 area (area-based)來取出要輸入類神經網路作為訓練的 MN 換手與軌跡資料，而剩下沒作為訓練用的資料將用來做為類神經網路預測使用。如此，相較於單純由最前面的 MN 行動資料中取出訓練比例所需，本實驗將可以正確訓練到相鄰所有 cell 或 area，減少訓練時間，並提高預測準確度。

(1) **傳統同質性網路上以細胞為基礎(cell-based)方式**: 傳統同質性網路上只能針對鄰近的相同類型無線網路細胞加以預測，無法預測會換手到不同類型的無線網路細胞，因此即使有其他網路的細胞覆蓋同樣空間，MN 還是只能在原來相同網路的細胞間換手。本實驗將分別根據 MN 初始化時所在網路(Micro-cell or Macro-cell)，分別預測 MN 將會移動到同種網路內相鄰六個細胞的可能性，分別稱為"cell-based-macro"方法與"cell-based-micro"方法。若要擴充這種傳統同質性網路預測方式的缺點在於執行垂直預測時，每種異質性無線網路都需要一個完整的類神經網路，事先訓練後才能預測，每個網路預測後的結果還要進一步處理，才能選出目標細胞，造成系統資源的大量浪費。此外，每種無線網路都要執行一次預測，造成過長的預測延遲時間。但我們將以 cell-based-macro 與 cell-based-micro 方法的準確度與本論文所提 area-based 方式的準確度比較，證明 area-based 比 cell-based 相當或更好，可以採用為垂直性動預測的策略。cell-based 準確度算法為公式(5)。

$$A_i = \frac{\text{真正}handoff\text{到}cell_i\text{的百分比}}{\text{預測}handoff\text{到}cell_i\text{的百分比}} * 100\% \qquad (5)$$

(2) **本論文所提出以區域為基礎(area-based)方式**：經過前述類神經網路的訓練，挑選出最高可能性的區域後，再參考資源地圖選擇出此區域涵蓋到的所有不同種類網路上的目標細胞。若有兩種以上不同網路的目標細胞可以選擇，將以亂數方式平均選擇 MN 將垂直換手到的目標細胞，並接著繼續執行下去。相較於 cell-based 方法，將只需要一個類神經網路執行預測，能有效減少資源的使用與預測的延遲時間，並且可以在不同類型的無線網路細胞間換手。關於 area-based 準確度算法為公式(6)。

$$A_i = \frac{\text{真正}handoff\text{到}area_i\text{的百分比}}{\text{預測}handoff\text{到}area_i\text{的百分比}} * 100\% \qquad (6)$$

3.2 結果分析

在本實驗中有 micro-cell 與 macro-cell 兩種無線網路同時存在，因此在 cell-based 下將有兩種 cell-based-macro 與 cell-based-micro 方式，依據預測可能性由高到低排名六個相鄰細胞的準確度。而在 area-based 下，類神經網路會預測出 6/12/18 個區域每一個區域的可能會成為換手的區域的機率，再根據公式(6)得到此 area-based 的預測準確度。為了與六個相鄰 cell 的 cell-based-macro 與 cell-based-micro 方式比較準確度，12/18 個區域 area-based 的方式，會將類神經網路預測出的分數由大到小排列並且兩/三個分數合併，最後合併成為 6 個分數。因為 MN 真正換手時只會換手到相鄰某個 Macro(Micro)Cell / Area，而其理想機率為 1，其他的 Cell/Area 機率都為 0，但預測結果並不會如此理想。我們將利用 Mean Square Error 公式（公式 7）比較出所有不同方式的準確度。

MSE=

$$\sqrt{(X_1-1)^2+(X_2-0)^2+(X_3-0)^2+(X_4-0)^2+(X_5-0)^2+(X_6-0)^2} \qquad (7)$$

其中 X_i 是 A_i 經過降冪排序後之結果，即 X_1 是所有合併後 cell/Area 預測準確度最高者(即為實際預測到之 area)，X_6 是所有合併後 cell/Area 預測準確度最低者。五種方法中 MSE 最低者的預測準確度最高。

由圖十、十一、十二觀察得知，當訓練比例一樣的時候，(1)由於在 macro-cell 的直徑大小(1600m)是 micro-cell (800m)的兩倍，一個 macro-cell 擁有平均四倍於一個 micro-cell 的面積，且我們所設計的 city map 中 MN 多數集中在道路或建築物的方向移動，因此 cell-based-macro 方式下 MN 換手的 cell 會較為集中，導致 cell-based-macro 方式下 MSE 明顯小於 cell-based-micro 方式下 MN 換手的 MSE。(2) 在 area-based 中的 6-area 方式，由於能夠在換手時隨機選擇換到相鄰的 micro-cell 或 macro-cell，因此 6-area 方式的 MSE 會介於 cell-based-macro MSE 與 cell-based-micro MSE 之間。(3) 12-area/18-area 所得到的 Mean Square Error 跟傳統的 cell-based 或 6-area 比起來大大的降低，因此切割成為較多的 area 會有較低的 MSE，即較高的準確度。但切割成為 18-area 並沒有比 12-area 有明顯的 MSE 下降，因此，或許切割成 12-area 左右是預測演算法準確度與複雜度之間的平衡點。(4) 在訓練比例較多的數據可知，當訓練比例越多時，相較於傳統的 cell-based 方式，area-based 中的 12-area/18-area 的 Mean Square Error 下降越多，表示

12-area/18-area 方式真正達到訓練的效果。(5) 在相同訓練比例下，MN node 數目越多，提供訓練類神經網路的資料也越多，一般而言，20000 node 的 MSE< 10000 node MSE < 5000 node MSE。若是 MN node 較少(如 5000 node)。由圖十三、十四、十五觀察得知，當固定在相同 node 條件下時，由數據可得知(1) 若訓練比例越高時則 Mean Square Error 越是降低，因此在類神經網路中若我們有較多的歷史紀錄作為訓練數據時，可以降低 Mean Square Error，即提高預測準確度。(2) 而且在 area-based 中的 12-area、18-area 的 Mean Square Error 逐漸降低，即準確度升高，表示較多的 area 數可以提高預測準確度。但是 12-area 與 18-area 的 MSE 差距已經趨於平緩，表示分成 12 個 area 或許應該已經足夠，不需分割成為 18 個 area。(3) 在某種 MN 個數與 MSE（準確度）要求下，可以參考數據選擇最低的訓練比例，降低類神經網路訓練時間，提高此 area-based 預測系統的可用度。

4.結論(Conclusions)

本研究提供一個有效而準確以區域為基礎的垂直行動預測機制，透過自動建立以區域為基礎的外在資源的方式，採行 BPN 類神經網路來訓練歷史垂直換手的資料。

Reference

[1] A. Misra, S. Das, A. Dutta, A. McAuley and S.K. Das,"IDMP-Based Fast Handoffs and Paging in IP-Based 4G Mobile Network, "IEEE Communications Magazine, Vol.40, pp.138-145, Mar 2002

[2] H.W. Hwang, M.F. Chang and C.C. Tseng, "A direction-based location update scheme with a line-paging strategy for PCS networks," IEEE Communications Letters, Vol.4, pp. 149 -151, May 2000

[3] J. Misic, S.T. Chanson and F.S. Lai, "Admission Control for Wireless Networks with Heterogeneous Traffic Using Event Based Resource Estimation," the 6th International Computer Communications and Networks Conference, pp.262-269, Sep 1997.

[4] W.S. Soh and H.S. Kim, "Dynamic bandwidth reservation in hierarchical wireless ATM networks using GPS-based prediction, "Vehicular Technology Conference (VTC), Vol.1, pp.528-532, Fall 1999

[5] W.W.H. Yu and C.H. He, "Resource Reservation in Wireless Networks Based on Pattern Recognition," IEEE International Joint Conference on Neural Network (IJCNN'01), pp.2264-2269 Vol.3, 2001.

[6] Ching-Hsiang Wang, "A Dynamic Resource Allocation for Vertical Handoff on Heterogeneous Wireless Networks", Master Thesis, Institute of Information Management, Chaoyang University of Technology, Jul. 2003.

[7] J. Kaufman, J. Myllymaki, and J. Jackson, "City Simulator V2.0," IBM alphaWorks, Dec. 2001.

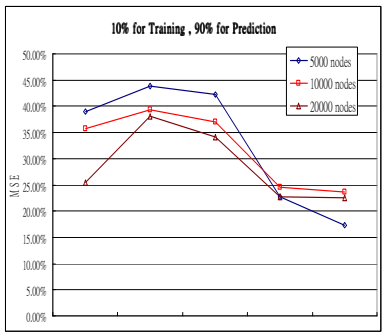

圖十、10%做為訓練用 90%做為預測用

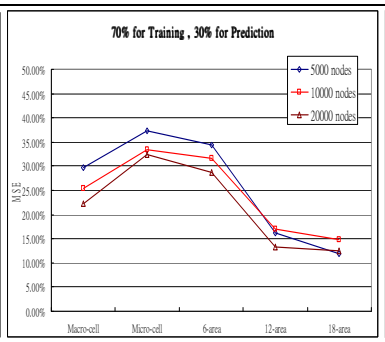

圖十一、40%做為訓練用 60%做為預測用

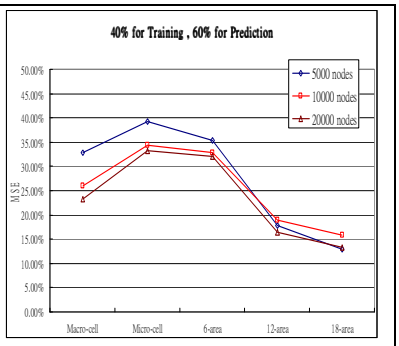

圖十二、70%做為訓練用 30%做為預測用

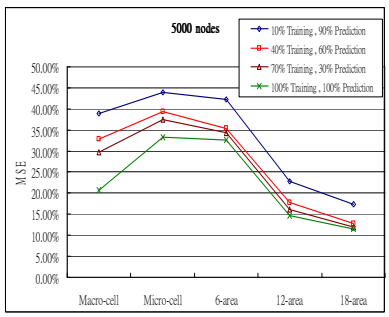

圖十三、5000 nodes 不同訓練比例

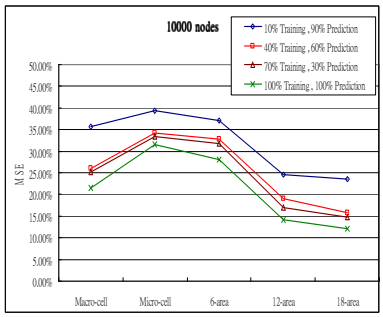

圖十四、10000 nodes 不同訓練比例

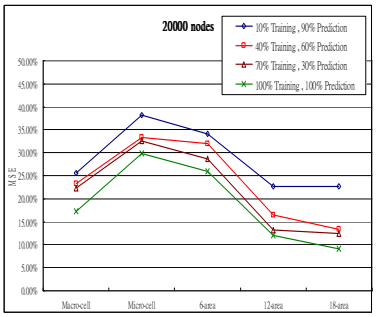

圖十五、20000 nodes 不同訓練比例