

基於趨勢觀察之預測器在微電網上之應用

鄭儀誠 傅家麟 徐振凱

工業技術研究院能源與環境研究所
31040 新竹縣竹東鎮中興路4段195號

摘要

本文提出了一個基於趨勢觀察之預測器，演算法是利用離散化的純預測器和數據累加生成運算的前處理，主要特點是具有最少的計算量、較大的預測長度以及非基於模式之預測，以致於有較廣的應用性，從驗證範例和電力負載預測的應用結果，可以證實根據少量的數據，提出的方法能簡單地提供滿意的預測。

關鍵詞：灰色預測，累加生成運算，z 轉換，電力負載預測

Trend-Observation-Based Predictor: Applications to a Micro-Grid

YI-CHENG CHENG, CHIA-LIN FU and CHEN-KAI HSU

*Energy and Environment Research Laboratories, Industrial Technology Research Institute
No. 195, Sec.4, Chung Hsing Rd., Chutung, Hsinchu, Taiwan 31040, R.O.C.*

ABSTRACT

A predictor based on the trend observation is proposed in this paper. The algorithm of which utilizes a pure predictor in discrete time and the data pre-processing of an accumulated generating operation with properties of the low calculation load, longer prediction horizon and non-model-based prediction possessed of great adaptation to applications. The proposed method simply gives the satisfactory prediction according to a few data and is verified from demonstration examples and a result of power load forecasting.

Key Words: grey forecasting, accumulated generating operation, z-transform, power load forecasting

一、緒論

近幾十年來全球經濟快速成長，開發中國家對石化燃料的需求與日劇增，尤其是中國大陸和印度，造成石化燃料的大量使用，由於石油、煤等蘊藏量有限，以及使用後增加溫室氣體的排放，對人類的生活環境和經濟活動已經產生了負面的影響，另一方面，也因為經濟的活絡使得用電需求增加，進而要求穩定安全的能源供應，為了因應溫室氣體排放減量、未來能源安全等挑戰，擴大再生能源供應及分散式能源的利用，已成為各國重要的能源政策，以歐盟而言，在其推動再生能源白皮書中，將再生能源的利用率，從 1995 年的 6%，計畫在 2010 年增加到 12%，另外，美國能源部規劃在 2010 年時，分散式能源要占總新增能源容量的 20%。

傳統的能源供應系統屬於「集中式」，先以一定的經濟規模來產生大量的電力，然後再經由電力傳輸系統輸配到各地使用，其主要的特點是中央調控容易且一致性高。而所謂「分散式」能源系統，是指除了大電廠之外，能源還可以由一般使用者、工業界或政府機構產生製造，例如家庭可以安裝太陽能發電面板來產生電力，化工廠等的氣電共生裝置，以及政府或農莊的風力發電等，分別在不同地點生產供應，除了可就地使用，也可經由輸配網路匯集共用，雖然個別的發電量相對於傳統的電廠，是顯得規模小而分散，但分散式能源的數目眾多，其總和就會十分可觀，最主要的是透過整體供需網路的管理機制，提供能源生產及能源節約的各種誘因，可更進一步促進再生能源的使用及用電效率。

包含分散式能源的微型電網 (micro-grid) 在能源控制與管理上面臨了一些挑戰，不同於傳統電網的運作方式，由於像風力、太陽能等再生能源的供應不穩定，以及微型電網內的電力負載需求在統計上的總量不確定性，造成供電可靠性的下降，因此微型電網的電力管理策略就是先要正確預測出所有再生能源的發電量以及負載需求的使用量，能源管理系統 (energy management system, EMS) 才能作電力平衡配置等規劃及運作。一般而言風力的出力預測大都採用類神經網路的作法 [7]，而太陽能的出力預測可分為三種方式：1. 利用過去的歷史資料，包含溫度、日照量 (radiation) 等，經由類神經網路、Kalman filter 等方法，建立長短期的溫度、日照量與發電量預估 [6, 9]；2. 利用攝影機觀察天空中的太陽與雲量，並使用高階影像辨識手法，偵測出雲朵移動方向，來推估未來天氣狀況的改變，以預測短時間內的發電量 [14]；3. 利用衛星雲圖分析目前時間與空間中雲量分佈與日

照情形，進而推估發電量 [8]。對於電力負載預測以時間序列分析 [4, 5] 最為廣泛應用。

然而上述的預測方法，通常需要大量的歷史數據或長時間的訓練，以及要花費可觀的電力來進行預測的計算，當應用的載台從微型電網再縮小至以家庭或大樓為主的更小型電網時，此時再生能源通常是發電瓦數較低的太陽能面板或風力發電機，其發電量相對較小，而電力負載可能不具週期性規則，因此預測計算所耗的電力以及硬體的計算能力和成本就需列入主要考量的因素，於是基於此動機，一個計算簡單、可立即使用和提供適當預測能力的預測器就被需要。

二、預測演算法

不同於常見的預測演算法，像類神經網路、馬可夫模型、迴歸模型、卡曼濾波器等，本文特別介紹一種實用的預測方法：灰色預測的 GM(1,1) 模型，會說明其主要原理，接下來本文採用灰色預測的數據前處理概念，並應用純預測器的作法，提出了基於趨勢觀察的預測器 (trend-observation-based predictor, TOP)，本文會藉由一些已知的動態系統來驗證其預測性能。

一般預測方法論的特性 [10] 比較見表 1，類神經網路通常需要較多的訓練資料且運算量龐大，但適用於大部分的問題且通常能有非常滿意的結果；時間序列的方法能獲得很好的預測結果，但主要問題在於建模需要花費大量的時間；而迴歸模型較難自動決定模型的類型，且針對非線性的系統會有顯著的預測誤差；至於 GM(1,1) 預測模型雖然學理不甚完美，但實際運用上卻相當實用；最後說明新演算法的主要特點是：1. 非基於模式之預測；2. 使用簡單；3. 具有最少的計算量。

(一) 灰色預測

鄧聚龍於 1982 年在國際期刊—System & Control Letters 上發表了論文 “The Control Problem of Grey Systems”，宣告了灰色系統理論的誕生，經過了近三十年來的發展，主要推廣於華人世界，特別是大陸地區。所謂灰色系統是指信息不完全、不確定之系統，而根據少量灰色系統的數據來做預測則稱之為灰色預測，針對單變數的一階預測模型 GM(1,1) [2]，其演算法步驟為：

步驟一：建立原始數據數列

$$X^{(0)} = \left(u^{(0)}(0), u^{(0)}(1), \dots, u^{(0)}(n) \right) \quad (1)$$

表 1. 預測方法論之特性比較

	本文方法	GM(1,1)	迴歸模型	時間序列	類神經網路
數據	≥4	≥4	≥30(建議)	≥100(建議)	越多越好
模式複雜度	無	低	低	高	低
自學習能力	不需要	有	無	無	有
模式類型	無	動態	靜態	靜態	動態
計算量	少	中	少	高	高

數據 $u^{(0)}(k) > 0, k = 0, 1, \dots, n$ 是實際得到的觀察值或量測值，用來建構 GM(1,1) 模型以預測未來值 $u^{(0)}(n+1)$ 等，值得注意的是若 $u^{(0)}(k)$ 包含正負號，則可將整個數列做前處理，例如：可將整個數列加上一個常數，本文建議選擇兩倍的數列最小值之絕對值。

步驟二：建立累加生成運算 (accumulated generating operation, AGO) 數列

$$X^{(0)} = (u^{(0)}(0), u^{(0)}(1), \dots, u^{(0)}(n))$$

$$= \left(\sum_{k=0}^0 u^{(0)}(k), \sum_{k=0}^1 u^{(0)}(k), \dots, \sum_{k=0}^n u^{(0)}(k) \right) \quad (2)$$

藉由數據前處理，特別是數據累加生成運算，目的是要發現潛在的規律，使得預測能夠準確，主要是由於影響系統變異的原因除了系統本身的動態行為外，還包含系統內外的擾動、量測雜訊等眾多因素，這些因素都伴隨著任意時間出現，而灰色預測並不像傳統的作法，將這些次效應去除，而是都將其列為主效應，並透過 AGO 的作法，得到符合實際現象的預測值。

步驟三：建立一階微分方程式描述 AGO 數列

$$\frac{dX^{(1)}}{dt} + aX^{(1)} = b \quad (3)$$

其中， a 稱之為發展係數 (developed coefficient)， b 為灰色控制變數 (grey controlled variable)。

步驟四：計算 AGO 數列的預測值

根據方程式 (3) 推導 $X^{(1)}$ 的解，並用來推估 AGO 數列的預測值：

$$\hat{u}^{(1)}(k+1) = \left(u^{(0)}(1) - \frac{b}{a} \right) e^{-ak} + \frac{b}{a} \quad (4)$$

參數 a 和 b 的獲得理論上是利用方程式 (4) 來對數列 (2) 做曲線擬合 (curve fitting)，但此方式並沒有解析解，因此灰色預測提出了所謂 GM(1,1) 源模型

$$u^{(0)}(k) + aZ^{(1)}(k) = b, k \geq 1$$

$$Z^{(1)}(k) = au^{(1)}(k) + (1-\alpha)u^{(1)}(k-1)$$

來近似方程式 (3)，此近似方程式就可利用最小平方來獲得 a 和 b 的近似參數值，結果如下

$$\begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (5)$$

$$B = \begin{bmatrix} -Z^{(1)}(1) & 1 \\ -Z^{(1)}(2) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix}, \quad Y_N = \begin{bmatrix} u^{(0)}(1) \\ u^{(0)}(2) \\ \vdots \\ u^{(0)}(n) \end{bmatrix}$$

一般而言， α 選擇為 0.5。

步驟五：計算 AGO 的逆轉換

$$\hat{u}^{(0)}(k+1) = \hat{u}^{(1)}(k+1) - \hat{u}^{(1)}(k) \quad (6)$$

步驟六：殘差檢驗

$$e(k) = \left| \frac{u(k) - \hat{u}(k)}{u(k)} \right|, k = 0, 1, \dots, n \quad (7)$$

$$\bar{e} = \frac{1}{n} \sum_{k=0}^n e(k)$$

殘差檢驗用來判斷預測模型的準確度。

值得一提的是若原始數列會隨著時間而更新且重複步驟一至六之程序，則此流程又稱之為滾動建模，通常利用四點以上的數據來做滾動建模，可以得到更好的預測結果，但

相對地會有較高的計算負荷。

最後，因為灰色預測是利用指數形式來描述 AGO 數列並以外插的方式來做預測，基本上其預測準確度會相關於 AGO 數列的分佈型態和發展係數 a ，從 GM(1,1) 的衍生模型可以得知若 $a \in (-2, 2)$ 則 GM(1,1) 的模型才有意義，對應於原始數列而言，級比 (class ratio) 的定義為

$$\lambda(k) = \frac{u^{(0)}(k-1)}{u^{(0)}(k)}, k \in \{1, 2, \dots, n\}$$

其值至少需滿足

$$\lambda(k) \in (0.135, 7.389), \forall k \tag{8}$$

(二) 基於趨勢觀察之預測器

Rad 和 Lo [12] 為了作時延系統的控制，在傳統控制器的輸出端加入了一個純預測器 $e^{T_p s}$ 來做時延補償，其中 s 是 Laplace 運算元， T_p 是預測時間，純預測器的動態關係為

$$Y(s) = e^{T_p s} U(s) \tag{9}$$

其中 $U(s)$ 和 $Y(s)$ 分別表示純預測器輸入和輸出的 Laplace 轉換。因為 $e^{T_p s}$ 是不可實現的，所以運用古典控制上常用的手法，就是先將其做 Maclaurin 級數展開：

$$e^{T_p s} = 1 + T_p s + \frac{T_p^2}{2!} s^2 + \dots + \frac{T_p^i}{i!} s^i + \dots = \sum_{i=0}^{\infty} \frac{T_p^i}{i!} s^i \tag{10}$$

將 (10) 式代入 (9) 式中，並作逆 Laplace 轉換則可得

$$y(t) = u(t + T_p) = u(t) + T_p \frac{du(t)}{dt} + \frac{T_p^2}{2!} \frac{d^2 u(t)}{dt^2} + \dots + \frac{T_p^i}{i!} \frac{d^i u(t)}{dt^i} + \dots \tag{11}$$

一般而言 (11) 式在運用上會遭遇兩個問題，第一是由於將訊號作微分的動作，若訊號含有噪音的情況下，則會造成噪音振幅放大的副作用，第二是涉及到無窮項合的計算，因此必須作可實現的近似：

$$y^*(t) = u^*(t + T_p)$$

$$= u_f(t) + T_p \frac{du_f(t)}{dt} + \frac{T_p^2}{2!} \frac{d^2 u_f(t)}{dt^2} + \dots + \frac{T_p^n}{n!} \frac{d^n u_f(t)}{dt^n} \tag{12}$$

其中 $u_f(t)$ 是經過濾波後的訊號，而 n 是級數擷取的有限項數。

然而 (12) 式在實際的預測應用上，也會面臨一些難題，包含離散時間的預測，以及造成微分副作用的原因不止只有噪音，像外界擾動、感測器和設備故障等因素皆可能誘發，所以本文提出新作法來獲得滿意的預測能力。

首先將 (9) 和 (10) 式離散化，也就是以差分 $(1-z^{-1})/T_s$ 來取代微分運算元 s ，其中 z 是 z 轉換運算元而 T_s 是取樣時間，透過二項式公式和歸納法則

$$\begin{aligned} \frac{Y(z)}{U(z)} &= \sum_{i=0}^n \frac{T_p^i}{i!} \left(\frac{1-z^{-1}}{T} \right)^i \\ &= \sum_{l=0}^n \left(\sum_{i=l}^n p^i \frac{(-1)^l}{(i-l)! l!} \right) (z^{-1})^l = \sum_{l=0}^n C_l (z^{-1})^l \end{aligned} \tag{13}$$

其中 $p = T_p/T_s$ 是預測長度。將 (13) 式作逆 z 轉換，在離散時間上的關係為

$$y(k) = u(k + p) = C_0 u(k) + C_1 u(k-1) + \dots + C_n u(k-n) = \mathbf{U}_n \cdot \mathbf{C}_n^T \tag{14}$$

其中， \mathbf{T} 是轉置運算元，以及

$$\mathbf{U}_n = [u(k-n) \quad \dots \quad u(k-1) \quad u(k)]$$

$$\mathbf{C}_n = [C_n \quad \dots \quad C_1 \quad C_0]$$

從 (14) 式可知，預測值僅是已知觀察向量 \mathbf{U}_n 和預測係數向量 \mathbf{C}_n 的內積，根據經驗通常選擇 $n \geq 3$ ，也就是根據觀察值的部分趨勢變化，就會有滿意的預測性能，而預測係數向量的元素是預測長度 p 的函數，所以一旦預測長度固定，則預測係數向量的數值就給定，一般而言可以透過查表的方式決定其係數，如表 2 所示，此基於趨勢觀察之預測器，並沒有使用任何的數學模型來做預測，因此會有較廣的適用性。

接下來可以根據實際預測對象的狀況，決定是否要作數據前處理，基本上以數據累加生成運算來代替濾波器，原因有二：1. 如同在灰色預測中所說明，因為無法去除所有的

表 2. 預測向量之元素表

n	p	C_n					
		C_5	C_4	C_3	C_2	C_1	C_0
3	1			-0.1667	1.0000	-2.5000	2.6667
	2			-1.3333	6.0000	-10.0000	6.3333
	3			-4.5000	18.0000	-25.5000	13.0000
4	1		0.0417	-0.3333	1.2500	-2.6667	2.7083
	2		0.6667	-4.0000	10.0000	-12.6667	7.0000
	3		3.3750	-18.0000	38.2500	-39.0000	16.3750
5	1	-0.0083	0.0833	-0.4167	1.3333	-2.7083	2.7167
	2	-0.2667	2.0000	-6.6667	12.6667	-14.0000	7.2667
	3	-2.0250	13.5000	-38.2500	58.5000	-49.1250	18.4000

次效應，所以用 AGO 數列來削弱變異的趨勢以獲得準確的預測，2. 可以簡化運算公式，獲得較快的計算速度。

基於趨勢觀察的預測器，其演算法步驟歸納如下：

步驟一：決定已知的觀察向量

$$\mathbf{U}_n^{(0)} = [u^{(0)}(k-n) \quad \dots \quad u^{(0)}(k-1) \quad u^{(0)}(k)]$$

如果 $\mathbf{U}_n^{(0)}$ 包含正負號，則將整個數列加上數列最小值之絕對值， $|\min(\mathbf{U}_n^{(0)})|$ 。

步驟二：計算 AGO 數列

$$\begin{aligned} \mathbf{U}_n^{(1)} &= [u^{(1)}(k-n) \quad \dots \quad u^{(1)}(k-1) \quad u^{(1)}(k)] \\ &= \left[\sum_{i=n}^n u^{(0)}(k-i) \quad \dots \quad \sum_{i=1}^n u^{(0)}(k-i) \quad \sum_{i=0}^n u^{(0)}(k-i) \right] \end{aligned}$$

步驟三：查表或計算出預測係數向量 \mathbf{C}_n

$$\mathbf{C}_n(p) = [C_n(p) \quad \dots \quad C_1(p) \quad C_0(p)]$$

$$\mathbf{C}_n(p-1) = [C_n(p-1) \quad \dots \quad C_1(p-1) \quad C_0(p-1)]$$

步驟四：計算 AGO 數列的預測值

$$u^{(1)}(k+p) = \mathbf{U}_n^{(1)} \cdot \mathbf{C}_n^T(p)$$

$$u^{(1)}(k+p-1) = \mathbf{U}_n^{(1)} \cdot \mathbf{C}_n^T(p-1)$$

步驟五：計算 AGO 的逆轉換

$$u^{(0)}(k+p) = u^{(1)}(k+p) - u^{(1)}(k+p-1)$$

如果在步驟一的原始數列有加上基準，則 $u^{(0)}(k+p)$ 需減去基準 $|\min(\mathbf{U}_n^{(0)})|$ 。

(三) 性能評估指標

為了評估預測器的性能，通常會定義一些和誤差量測相關的指標 [11]，在時間序列預測的領域上，預測誤差定義為量測值和預測值之差值，然而直覺上我們習慣將預測誤差定義為

$$\varepsilon(k+p|k) = \hat{u}(k+p|k) - u(k+p) \quad (15)$$

其中 $\hat{u}(k+p|k)$ 是根據 k 時刻以前的數據來預測未來 p 個時刻後的數值，而 $u(k+p)$ 是未來的實際觀察值。

一般而言，經常被使用來評估預測器的性能指標有四種：BIAS、MAE (mean absolute error)、RMSE (root mean squared error) 和 SDE (standard deviation of errors)。BIAS 和 MAE 分別定義為：

$$BIAS(p) = \bar{\varepsilon}_p = \frac{1}{N} \sum_{k=1}^N \varepsilon(k+p|k) \quad (16)$$

和

$$MAE(p) = \frac{1}{N} \sum_{k=1}^N |\varepsilon(k+p|k)| \quad (17)$$

這兩個指標值在統計上即為預測誤差的一階動差 (first

moment)，另外 RMSE 和 SDE 定義為

$$RMSE(p) = \left(\frac{1}{N} \sum_{k=1}^N \varepsilon^2(k+p|k) \right)^{1/2} \quad (18)$$

和

$$SDE(p) = \left(\frac{1}{N-1} \sum_{k=1}^N (\varepsilon(k+p|k) - \bar{\varepsilon})^2 \right)^{1/2} \quad (19)$$

在統計上代表的是預測誤差的二階動差，描述預測誤差的變異。

在實際運用上，通常會再將 BIAS、MAE 和 RMSE 指標做正規化 (normalize) 的處理，使得不同系統的預測結果能夠相互比較，正規化的步驟是將指標 BIAS、MAE 和 RMSE 除以量測值的平均，也就是

$$NBIAS(p) = 100 \times \frac{BIAS(p)}{\frac{1}{N} \sum_{k=1}^N u(k+p)} (\%) \quad (20)$$

$$NMAE(p) = 100 \times \frac{MAE(p)}{\frac{1}{N} \sum_{k=1}^N u(k+p)} (\%) \quad (21)$$

$$NRMSE(p) = 100 \times \frac{RMSE(p)}{\frac{1}{N} \sum_{k=1}^N u(k+p)} (\%) \quad (22)$$

(四) 範例驗證

範例一：考慮一個週期的正弦波訊號

$$u(t) = \sin(t), 0 \leq t \leq 2\pi$$

假設總取樣數為 50 點。驗證的方法是利用現在及過去所觀察到的 4 點數據來做未來第 3 個時刻的預測，首先根據上一節的基於趨勢觀察預測之演算步驟計算出第一次預測值：

步驟一：第一筆的原始觀察數列

$$\mathbf{U}_n^{(0)} = [\sin(0) \quad \sin(\Delta t) \quad \sin(2\Delta t) \quad \sin(3\Delta t)]$$

其中 $\Delta t = 2\pi/49$ 。

步驟二：計算 AGO 數列

$$\mathbf{U}_n^{(1)} = \left[\sum_{i=0}^0 \sin(i\Delta t) \quad \sum_{i=0}^1 \sin(i\Delta t) \quad \sum_{i=0}^2 \sin(i\Delta t) \quad \sum_{i=0}^3 \sin(i\Delta t) \right]$$

步驟三：因為選擇 $n=3$ 和 $p=3$ ，查表得知預測係數向量 $\mathbf{C}_n(p)$ 和 $\mathbf{C}_n(p-1)$ 為

$$\mathbf{C}_n(3) = [-4.5 \quad 18.0 \quad -25.5 \quad 13.0]$$

$$\mathbf{C}_n(2) = [-1.3333 \quad 6.0 \quad -10.0 \quad 6.3333]$$

步驟四：計算 AGO 數列的預測值

$$u^{(1)}(7) = \mathbf{U}_n^{(1)} \cdot \mathbf{C}_n^T(3) = 2.4111$$

$$u^{(1)}(6) = \mathbf{U}_n^{(1)} \cdot \mathbf{C}_n^T(2) = 1.7450$$

步驟五：計算 AGO 的逆轉換

$$u^{(0)}(7) = u^{(1)}(7) - u^{(1)}(6) = 0.6661$$

上式即為 $\sin(6\Delta t)=0.6956$ 的預測值。同樣地，更新原始觀察數列 $\mathbf{U}_n^{(0)}$ 並重複步驟一至五，則可獲得整個時段的預測值，值得注意的是在計算過程中步驟三只要計算一次。

預測和實際觀察的結果可見圖 1，圖中也包含了灰色預測的結果，將兩種預測方法的誤差量測列於表 3，從表 3 可輕易地得知，本文所提出的方法有令人滿意的預測性能，而典型的灰色預測出現部分偏離目標值的結果，原因可從其預測的第一點結果來做說明，圖 2 的實線部分是觀察值的累加生成數列，而虛線是灰色預測的結果，其後三點是預測的部分，而其前四點可用來做殘差檢驗以驗證模式的準確性，然而從該圖發現，其預測模式的準確性很高，但無法作較長的預測，原因就是因為指數形式的模式假設，其外差預測的靈敏度受預測長度的影響很大，就會造成越長的預測，存在著更大的誤差。然而相對於此，基於趨勢觀察預測器針對欲預測之訊號，若訊號前後存在著豐富的關連性，則會有長的預測能力，可以用圖 3 來做進一步說明，該圖是利用 6 點的觀察值來預測 15 個時刻後的數值，從圖 3 發現，觀察值和未來的實際訊號值不在波形的同一側，本文所提出的方法，也能有好的預測結果。

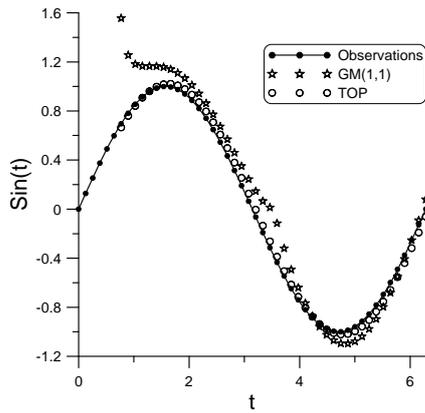


圖 1. 範例一之預測方法比較

表 3. 範例一之性能指標比較

Method	BIAS	MAE	RMSE	SDE
GM(1,1)	0.1083	0.1587	0.2125	0.1849
TOP	0.0055	0.0403	0.0452	0.0454

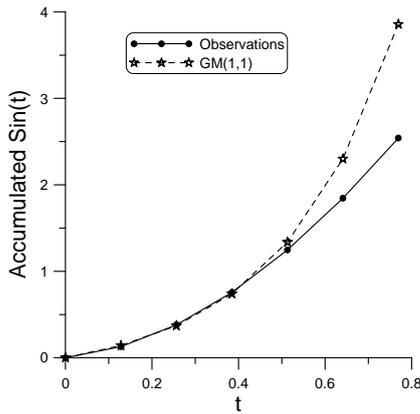


圖 2. 範例一中，累加生成數列的灰色預測

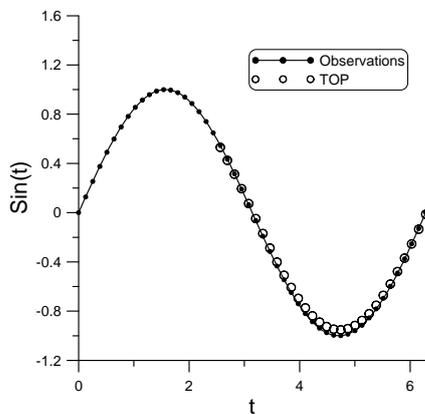


圖 3. 範例一之長預測能力驗證

範例二：考慮訊號

$$u(t) = \sin(t) + 2\cos(3t) + N(0, 0.1), 0 \leq t \leq 2\pi,$$

其中 $N(0, 0.1)$ 是表示平均為 0、標準差為 0.1 之常態分佈的噪音，除了測試噪音對預測演算法之影響外，將訊號的總取樣數設為 30 點，以評估當觀察數列的前後關連性低時，對預測結果的影響，結果見圖 4，一般而言在訊號轉折點時，容易產生過高或過低的預估值，而且預測器的長遠預測能力較差，此一情況同樣也會發生在一般常見的預測演算法，最後將性能指標的比較整理於表 4，不過整體而言，本文方法的預測趨勢和追蹤能力是令人滿意的。

四、應用範例－電力負載預測

一個地區的電力負載會隨著用戶的需求隨時發生變化，而用戶的需求又相關於氣候以及人文活動的影響，在本質上大區域的總電力負載是具非穩定的週期性，例如：週末假日、工作日和節慶假日的電力需求型態並不相同 [3, 13]，再加上電力無法大量儲存的特性，因此電力負載預測不論在電力輸配作業、儲存能源調配或緊急事故處理中均扮演重要的角色。

在本節，以國立中央大學國鼎圖書資料館 5 樓的電力負載 [1] 為預測對象，用以評估所提的預測演算法在電力需

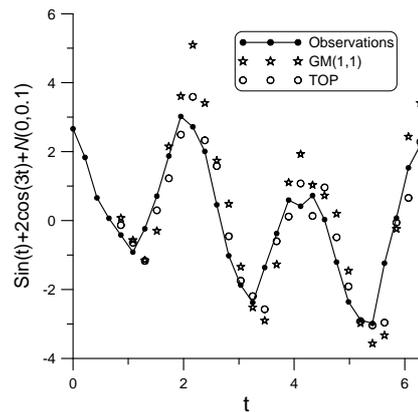


圖 4. 範例二之預測方法比較

表 4. 範例二之性能指標比較

Method	BIAS	MAE	RMSE	SDE
GM(1,1)	0.3323	0.9168	1.0858	1.0542
TOP	-0.0480	0.5558	0.6867	0.6986

求端的負載預測能力,以作為後續在微電網中能源管理系統的軟體功能規劃。該建築物使用的電力有 110V 和 220V 兩類,根據統計資料,其用電比例有 57% 用於照明和動力設備,43% 用於空調設備。本文針對週末假日和平常工作日的電力負載來做預測,圖 5 和圖 6 分別是 2004 年 5 月 22 日(星期六)時 110V 和 220V 的電力負載量測及預測的結果,使用的預測方法有 GM(1,1) 和基於趨勢觀察之預測器,值得注意的是圖中 GM(1,1) 的某些預測結果並沒有被呈現,是因為 GM(1,1) 的預測模型無法算出合理或有意義的數值,所以為了圖形的清楚表示而將這些值省略不計;同樣地,針對 2004 年 5 月 25 日(星期二)的預測結果繪於圖 7 和圖 8,從這些圖發現電力負載跟圖書館的開放時間相關,當早上開放時,照明及空調的電力需求劇增,造成電力負載有類似步階式的改變,而當圖書館要閉館時,也會發生同樣的情況。為了評斷預測結果的優劣,將預測誤差的計算結果整理於表 5,因為量測的電力負載都是正值,為了便於比較,可以採用正規化的指標,從表 5 得知,所提出方法的 NMAE 和 NRMSE 都比灰色預測來的低,也就是本文的方法有較好的預測能力,但因為外生變數所造成的原因以及較長的取樣時間,使得部分預測會得到較差的結果,除了在工作日的 220V 電力負載的部分預測外,一般而言符合一個計算簡單、可立即使用和提供適當預測能力的預測器之需求。

五、結論

根據灰色預測的數據前處理概念,並應用離散時間的純預測器,提出了基於趨勢觀察之預測器,新演算法的主要特

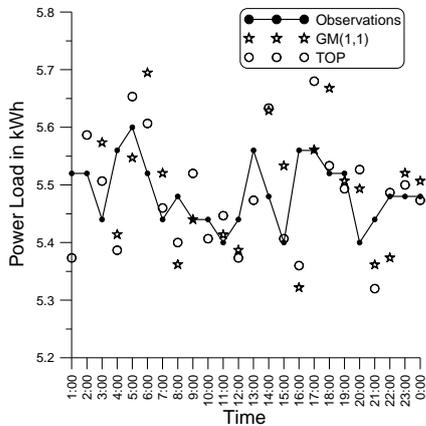


圖 5. 2004 年 5 月 22 日(星期六)的 110V 電力負載量測及預測

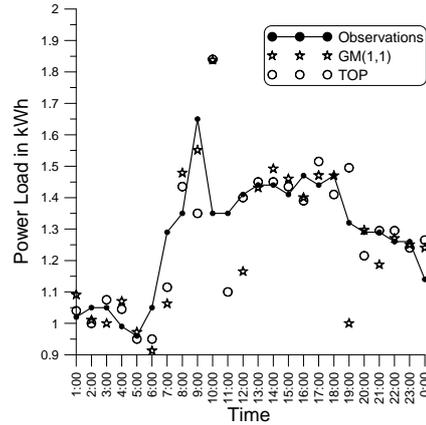


圖 6. 2004 年 5 月 22 日(星期六)的 220V 電力負載量測及預測

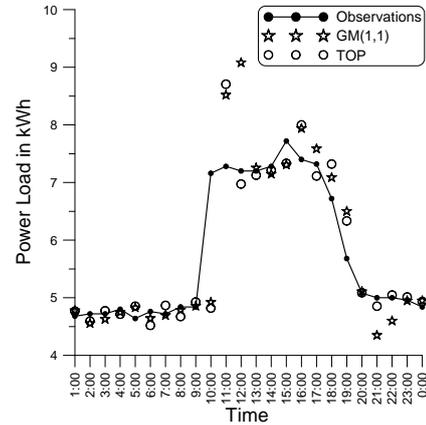


圖 7. 2004 年 5 月 25 日(星期二)的 110V 電力負載量測及預測

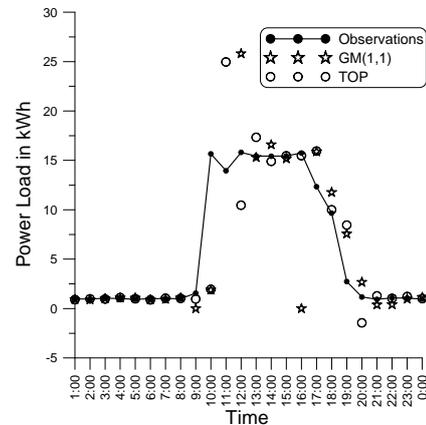


圖 8. 2004 年 5 月 25 日(星期二)的 220V 電力負載量測及預測

表 5. 電力負載預測的性能指標比較

日期		NMAE (%)		NRMSE (%)	
		GM(1,1)	TOP	GM(1,1)	TOP
2004 年 5 月 22 日 (星期六)	110V	--	1.3720	--	1.7009
	220V	11.9925	7.3659	24.5134	11.4572
2004 年 5 月 25 日 (星期二)	110V	7.1866	5.8699	12.3190	10.6893
	220V	48.1435	31.8355	93.1287	66.3096

註：-- 表示無數值。

點是 (1) 非基於模式之預測；(2) 使用簡單；(3) 具有最少的計算量。從驗證範例發現若欲預測的訊號前後存在著豐富的關連性，則會有較好及較長的預測能力，反之在訊號轉折點時，容易產生過高或過低的預估值。最後從電力負載預測的實際案例也可說明本文提出方法之簡單及可接受性。

參考文獻

- 傅家麟 (民 94)，室內微環境監測系統之開發-以室內環境與用电量相關性研究為例，國立中央大學環境工程研究所碩士論文。
- 鄧聚龍、郭洪 (民 88)，灰預測模型方法與應用，頁 1-28，高立圖書有限公司，台北。
- Adepoju, G. A., S. O. A. Ogunjuyigbe and K. O. Alawode (2007) Application of neural network to load forecasting in Nigerian electrical power system. *The Pacific Journal of Science and Technology*, 8(1), 68-72.
- Box, G. E. P., G. M. Jenkins and G. C. Reinsel (1994) *Time Series Analysis-Forecasting and Control*, 3rd Ed., 131-180. Prentice-Hill, Inc., London.
- Catlin, D. E. (1989) *Estimation, Control, and the Discrete Kalman Filter*, 1st Ed., 133-163. Springer-Verlag, New York.
- Chaabene, M. (2008) Measurements based dynamic climate observer. *Solar Energy*, 82(9), 763-771.
- Degner, T., J. Schmid and P. Strauss (2006) *Distributed Generation with High Penetration of Renewable Energy Sources: Final Public Report*. Dispower, Kassel, Germany.
- Hammer, A., D. Heinemann, E. Lorenz and B. Lucke (1999) Short-term forecasting of solar radiation: A statistical approach using satellite data. *Solar Energy*, 67(1-3), 139-150.
- Hontoria, L., J. Aguilera, F. Almonacid, G. Nofuentes and P. Zufiria (2006) Chapter 5: Artificial neural networks applied in PV systems and solar radiation. *Artificial Intelligence in Energy and Renewable Energy Systems*, 1st Ed., Nova Science Publishers, Commack, NY.
- Lin, C. T., C. W. Chang and C. B. Chen (2005) Relative control philosophy-balance and continuous change for forecasting abnormal quality characteristics in a silicon wafer slicing process. *The International Journal of Advanced Manufacturing Technology*, 26(9-10), 1109-1114.
- Madsen, H., P. Pinson, G. Kariniotakis, H. A. Nielsen and T. S. Nielsen (2005) Standardizing the performance evaluation of short-term wind power prediction models. *Wind Engineering*, 29(6), 475-489.
- Rad, A. B. and W. L. Lo (1994) Predictive PI controller. *International Journal of Control*, 60(5), 953-975.
- Song, K. B., Y. S. Baek, D. H. Hong and G. Jang (2005) Short-term load forecasting for the holidays using fuzzy linear regression method. *IEEE Transactions on Power Systems*, 20(1), 96-101.
- Yamamoto, S., T. Katagi, J. Park and T. Hashimoto (1999) A basic study to forecasting the power fluctuation of the photovoltaic power generation by image processing of clouds. *Transactions of the Institute of Electrical Engineers of Japan. B*, 119-B(8-9), 909-915.

收件：97.10.01 修正：97.10.30 接受：97.11.21