

Study of Solar Power Probabilistic Forecasting using parametric, non-parametric and hybrid model methods

參數、非參數方法及混合模型方法之太陽光電機率預測研究

指導教授: 吳元康

學生: 莊詠淳、林弘鈞

背景介紹

隨著再生能源在電力系統中占比逐漸提高，太陽光電因受氣候、日照等環境因素影響，其輸出功率具有高度的波動性與不確定性，因此準確的功率預測對電網調度與穩定運轉相當重要。近年來，機率預測逐漸取代傳統的單點預測，能夠提供預測結果的不確定性資訊。本研究針對太陽光電功率預測問題，分別採用參數方法（Gaussian, Beta）、非參數方法（KDE, LUBE, Quantile Regression）以及混合模型（MMC），進行系統性之比較與分析。以實際光電場域逐時發電資料為研究對象，並以 PICP、PINAW、CWC 等指標進行評估。綜合分析結果可為再生能源機率預測方法之選擇與應用提供參考，亦能作為後續電網運轉與併網分析之基礎。

機率預測實作

本研究針對台灣台南太陽能案場(經緯度:120.3373, 23.1798649、裝置容量: 251.685kW)進行太陽光電發電量的小時前預測，預測時段為早上6點至晚上6點。模型輸入變量有歷史量測數據發電量、歷史量測數據量測照度、以及中央氣象署所提供的數值天氣預報模式的氣象參數(包含照度、雨量、溫度、氣壓、風速)的數值，輸出變量為發電量。案場訓練時間為2019.07.03 - 2019.10.15的數據，測試時間為2019.10.16 - 2019.11.10的數據。針對Gaussian, Beta, KDE, LUBE, QR與MMC方法分別進行探討與比較。以下以MMC方法為代表展示預測流程及結果，圖1為MMC方法的流程示意圖; 圖二為MMC方法的切分數據示意圖; 圖3為案場小時前機率預測應用於MMC方法中以一個星期為基礎呈現的機率預測圖。

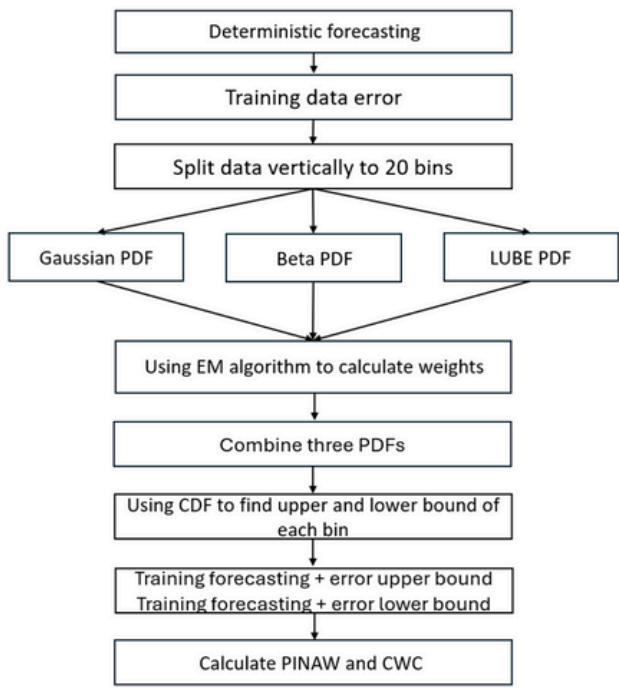


圖 1 MMC方法流程圖

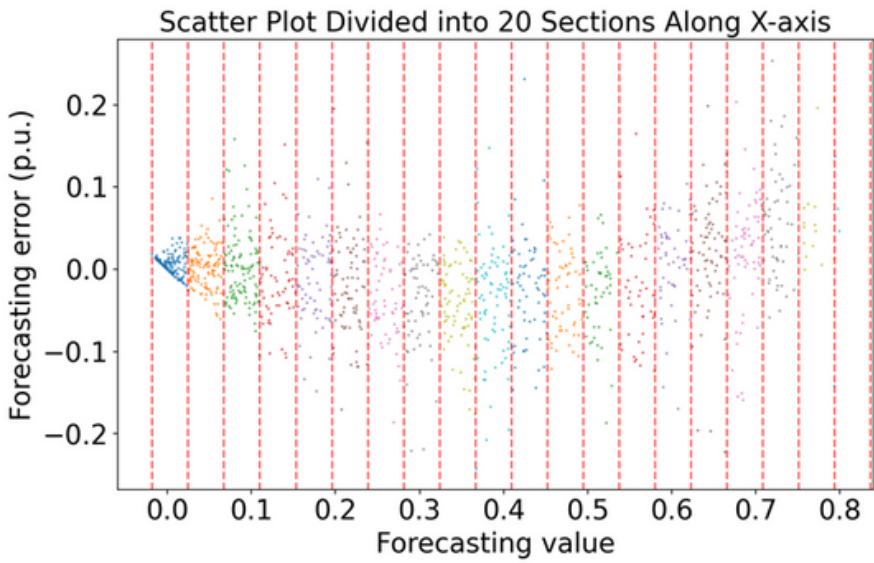


圖 2 小時前預測訓練資料利用MMC方法的切分數據示意圖

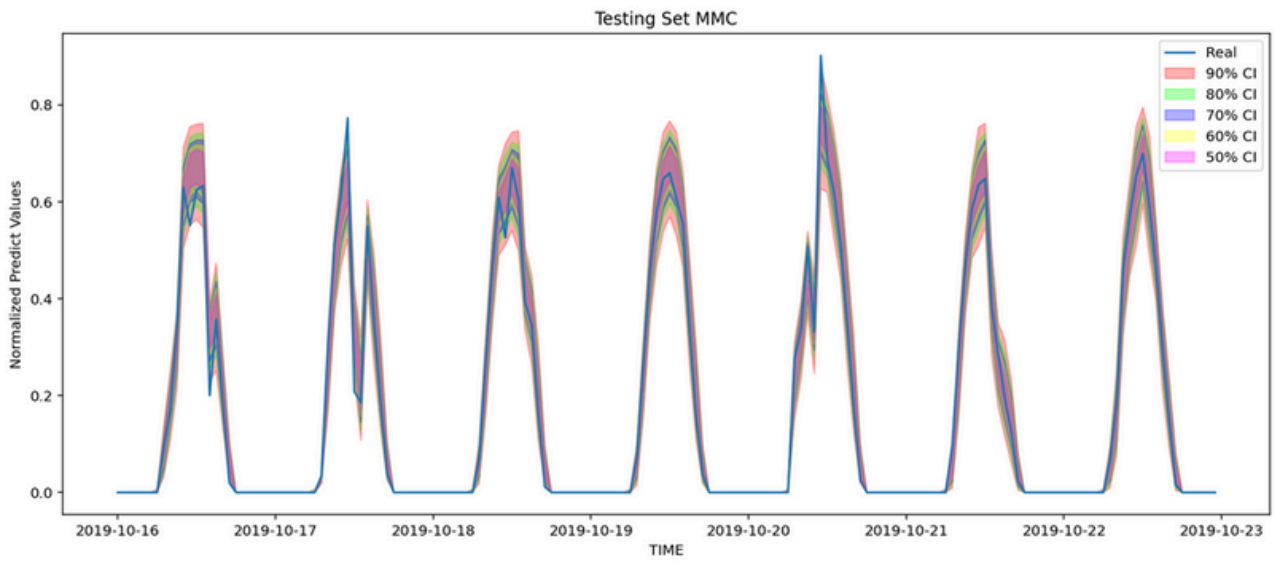


圖 3 機率預測圖_MMC

實作結果比較

Type	參數方法						混合模型方法		
Method	Gaussian Distribution			Beta Distribution			MMC		
CI(%)	PICP	PINAW	CWC	PICP	PINAW	CWC	PICP	PINAW	CWC
90%	0.9531	0.1679	0.1679	0.9179	0.1928	0.1928	0.9537	0.0882	0.0882
80%	0.8915	0.1308	0.1308	0.912	0.1807	0.1807	0.9377	0.0666	0.0666
70%	0.8182	0.1058	0.1058	0.8944	0.1649	0.1649	0.9153	0.053	0.053
60%	0.7302	0.0859	0.0859	0.8739	0.1464	0.1464	0.8594	0.0419	0.0419
50%	0.5953	0.0689	0.0689	0.8152	0.1254	0.1254	0.8147	0.0323	0.0323

Type	非參數方法								
Method	KDE			LUBE			QR		
CI(%)	PICP	PINAW	CWC	PICP	PINAW	CWC	PICP	PINAW	CWC
90%	0.9619	0.1864	0.1864	0.9707	0.1792	0.1792	0.9559	0.0579	0.0579
80%	0.8152	0.1361	0.1361	0.9003	0.1338	0.1338	0.8767	0.0455	0.0455
70%	0.7273	0.1067	0.1067	0.8211	0.1073	0.1073	0.7775	0.0384	0.0384
60%	0.6569	0.085	0.085	0.7273	0.0896	0.0896	0.638	0.0324	0.0324
50%	0.5601	0.0672	0.0672	0.5806	0.0696	0.0696	0.4978	0.027	0.0541

表 1 各方法指標結果比較表

根據表 1 的比較結果，若以區間狹窄性（PINAW）與綜合準則（CWC）為主要排序標準，方法表現由好到壞的順位為：QR → MMC → KDE → LUBE → Gaussian → Beta。

結論與未來方向

整體而言，非參數方法在本研究資料下表現最穩定，能有效維持高覆蓋率並縮小區間寬度；其中 QR 方法獲得最優結果，顯示其對於區間掌握與誤差適應的能力最為平衡。相較之下，參數方法在實際太陽光電資料中受限於分布假設，預測區間往往偏寬且保守，Gaussian 與Beta 方法雖可簡單生成機率區間，但對於異質性較高的誤差結構反應不足，在本研究中表現最差。混合模型方法則展現出整合優勢，MMC能透過結合多種分布資訊使整體預測結果更為穩定，兼顧準確度與一致性，結果優於任一參與結合的單一方法。基於本研究提出的內容仍有若干可延伸與改進的方向：

- 1.在資料層面方面，本研究主要聚焦於單一案場的太陽光電輸出，未來可擴充至更多地區、季節資料與不同案場，以評估方法在不同氣候條件、地理環境及容量規模下的穩健性。
- 2.MMC混合方法的參數調整策略可更動態化，例如利用貝氏更新（Bayesian updating）或時序加權平均機制，使模型能即時修正信賴區間寬度以對應不同誤差分佈。
- 3.開區間的方法。本文使用開信賴區間方法為統計上的其中一種開區間的方法，可以使用其他方法開區間依此增進機率預測的精度。
- 4.混合模型方法的權重最佳化，本研究只用一種EM演算法，未來可以嘗試其他方法並比較結果好壞。
- 5.混合模型方法的模型選用部分，可以加入機率檢定，例如K-S檢定，移除特定bin中一些誤差過大的參數機率分布。