



國立成功大學

National Cheng Kung University

能源科技與策略研究中心

Research Center for Energy Technology and Strategy

工業潔能於智能預測簡介

伍芳嫻 副研究員

國立成功大學 能源科技與策略研究中心



2022/07/13



國立成功大學

National Cheng Kung University

能源科技與策略研究中心


Research Center for Energy Technology and Strategy

人工智慧簡介



人工智慧歷史

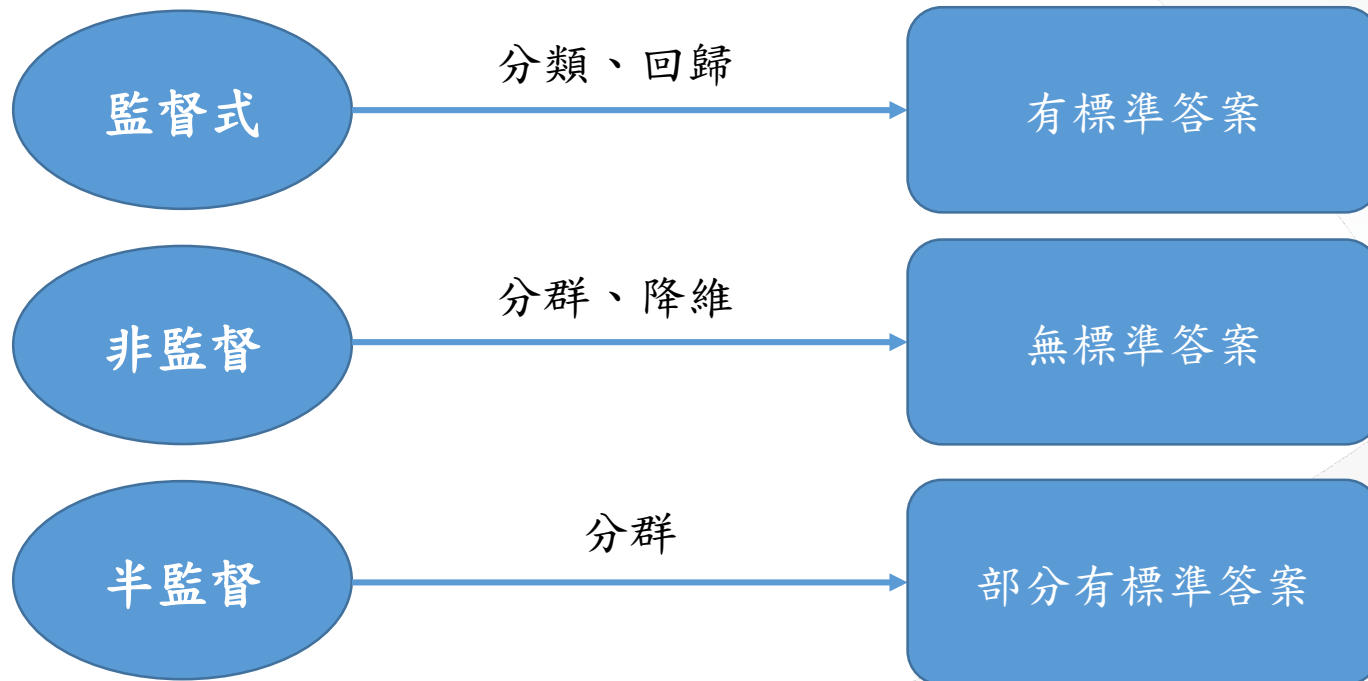
- 人工智慧最早於1956年由John McCarthy提出，至今共經歷三次熱潮。
 - 第一次熱潮 (1950-1970): 針對特定問題進行**搜尋**以及**推論**
 - 第二次熱潮 (1980-1990): 由專家針對問題推論出嚴謹的描述後建立**專家系統**
 - 第三次熱潮 (2000-): 隨著硬體、演算法的進步，**機器學習**開始蓬勃發展



機器學習

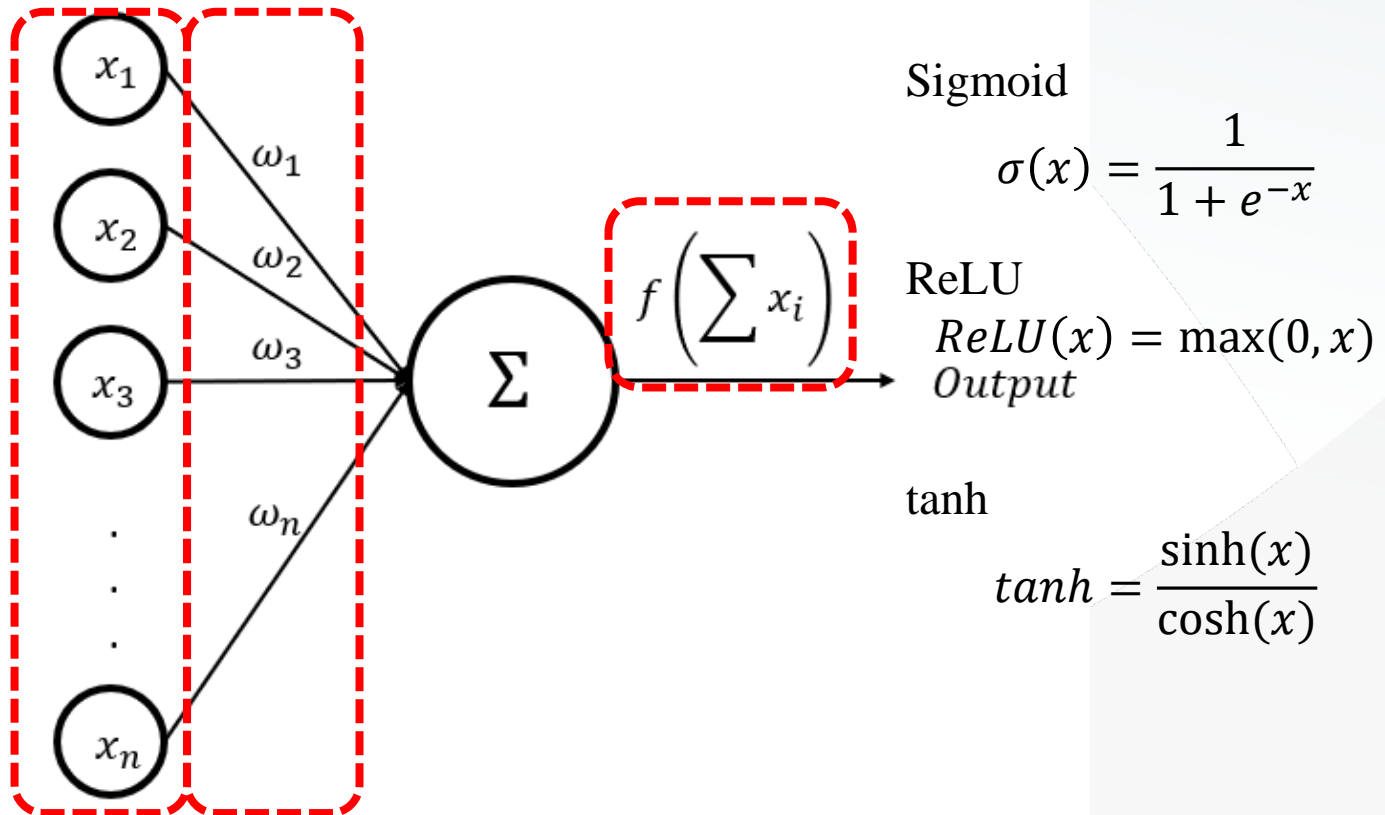
• 機器學習為實現人工智慧的方法之一，其依據資料可區分為以下三種：

- ① 監督式學習 (Supervised Learning): 輸入特徵與輸出目標皆給定
- ② 非監督式學習 (Unsupervised Learning): 無給定輸出目標
- ③ 半監督式學習 (Semi-supervised Learning): 給定部分資料之輸出




類神經網路(1/2)

- 類神經網路(Artificial Neural Network)為機器學習的一環，其基於類神經元(Artificial Neuron)。
- 一個類神經元接收輸入特徵，配置權重後加總並經由啟動函數(Activation Function)進行輸出。



類神經網路(2/2)

- 將多個類神經元串接形成類神經網路，其架構包含輸入層、隱藏層與輸出層。
- 若隱藏層層數大於一層，亦稱為深度神經網路，其學習方式則稱為深度學習。



訓練流程

- ① 向前傳播 → 當下預測
- ② 損失函數 → 誤差計算
- ③ 更新演算 → 梯度下降
- ④ 反向傳播 → 參數更新



國立成功大學

National Cheng Kung University

能源科技與策略研究中心


Research Center for Energy Technology and Strategy

案例介紹
 600kW_{th} 氣化爐 (PKS)



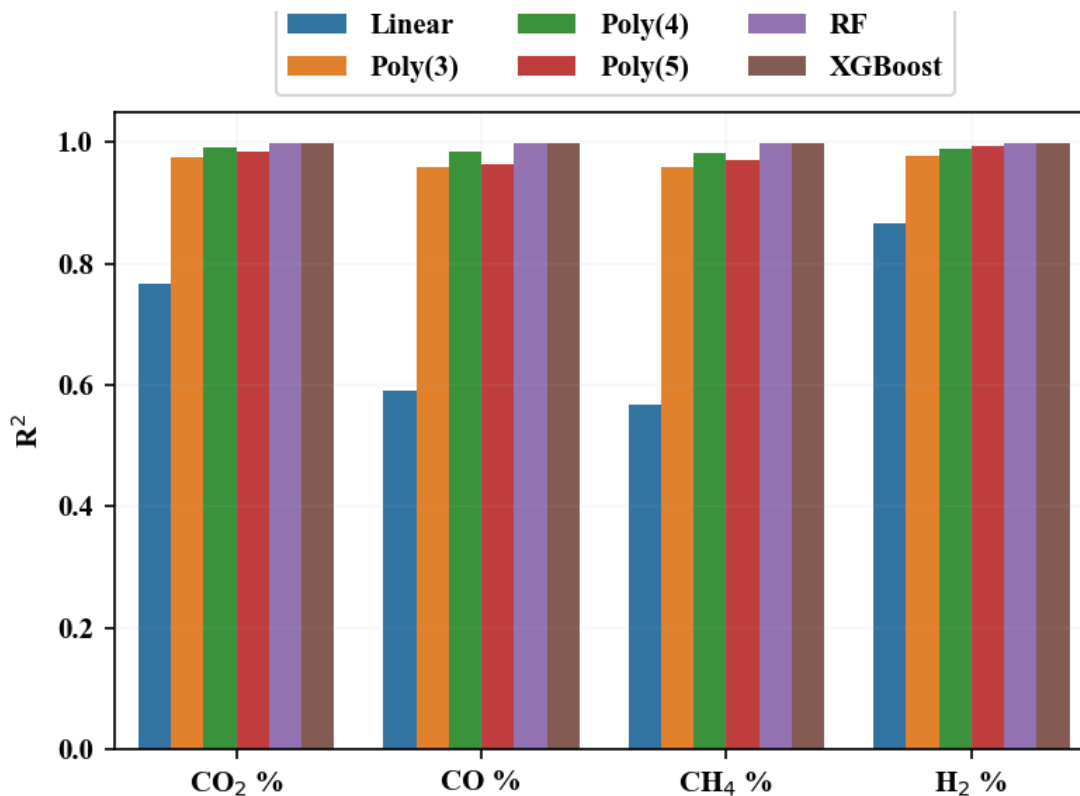
600kW_{th} 氣化爐(1/4)

- 此案例為利用本團隊既有的600kW_{th}流化床氣化爐系統，進行氣化產製合成氣做為輔助燃料進行燃燒應用之試驗
- 爐內不同高度的5個溫度點作為輸入特徵，預測目標為CO₂、CO、H₂與CH₄。



600kW_{th} 氣化爐(2/4)

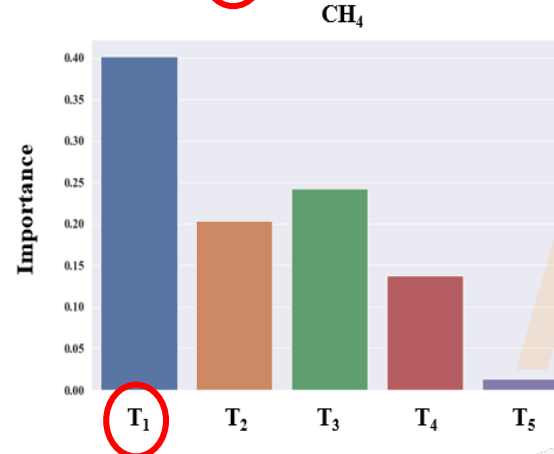
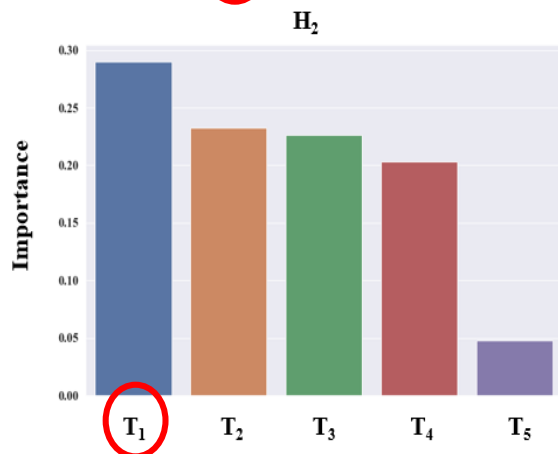

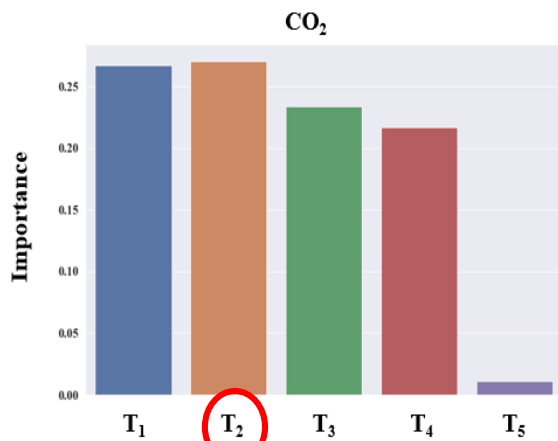
1. 透過關聯性分析，發現整體趨勢偏向弱非線性，故以線性回歸為基礎模型。
2. 以多項式方程進行修正，求出最適之階數(以3-5皆為例)。
3. 引入樹集成模型(隨機森林與XGBoost)，由於其演算特性，五個溫度點會被執行特徵篩選並預測。



- 回歸系列模型中，四階擬和效果最佳(H₂之5階略優於4階，但複雜度卻高出許多)
- 整體而言，樹集成模型表現非常接近，多次測試後仍為隨機森林擬和最佳。

600kW_{th} 氣化爐(3/4)

- 基於隨機森林之重要度分析 (以Gini不純度為考量)之結果:



① CO₂: T₂ > T₁ > T₃ > T₄ > T₅

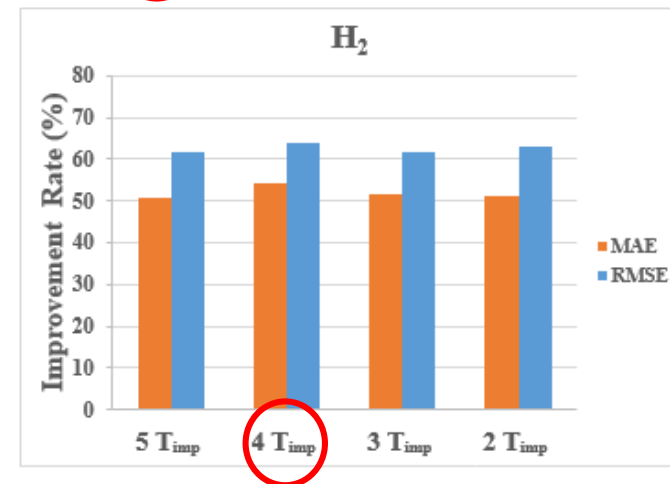
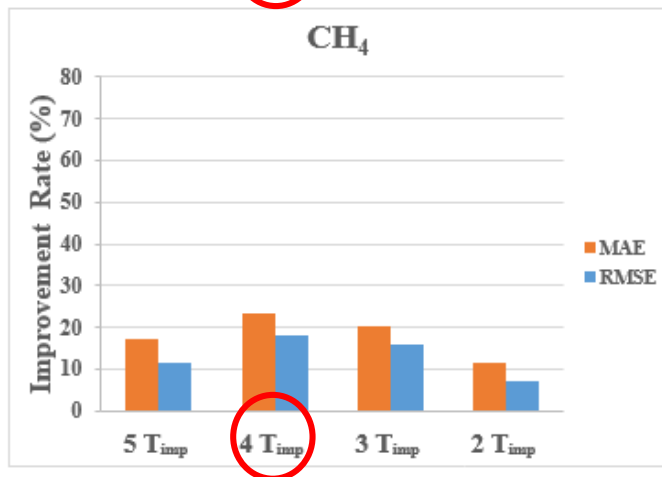
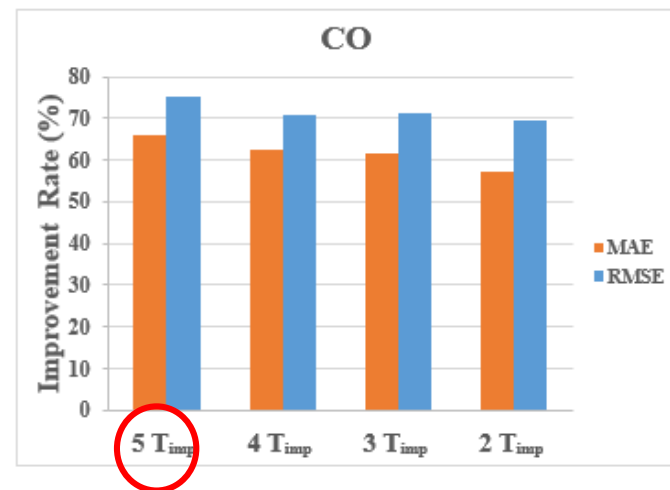
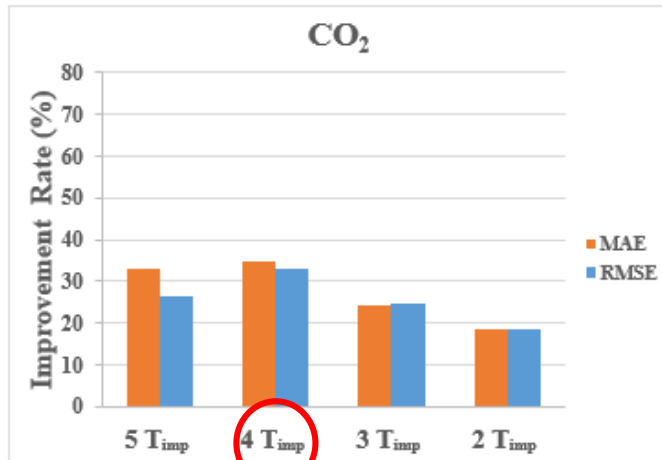
② CO: T₂ > T₁ > T₃ > T₄ > T₅

③ H₂: T₁ > T₂ > T₃ > T₄ > T₅

④ CH₄: T₁ > T₃ > T₂ > T₄ > T₅

600kW_{th} 氣化爐(4/4)

- 設定**最重要的溫度點**作為**唯一**的輸入特徵，並計算MAE與RMSE作為比較基準：
- 水平軸 $n T_{imp}$ 代表採用**前 n 個重要的溫度點**作為輸入特徵





國立成功大學

National Cheng Kung University

能源科技與策略研究中心

Research Center for Energy Technology and Strategy


案例介紹

1kW_{th} 氣化爐 (SS + PKS)



1kW_{th} 氣化爐(1/6)


Experiment no.	Temperature (°C)	Blending ratio (%)	CO ₂ /agent gases (%)	Catalyst (%)
1	750	0	55	0
2	750	20	70	15
3	750	30	85	20
4	750	40	100	25
5	800	0	70	20
6	800	20	55	25
7	800	30	100	0
8	800	40	85	15
9	850	0	85	25
10	850	20	100	20
11	850	30	55	15
12	850	40	70	0
13	900	0	100	15
14	900	20	85	0
15	900	30	70	25
16	900	40	55	20



每筆實驗約為1小時左右數據

1kW_{th} 氣化爐(2/6)

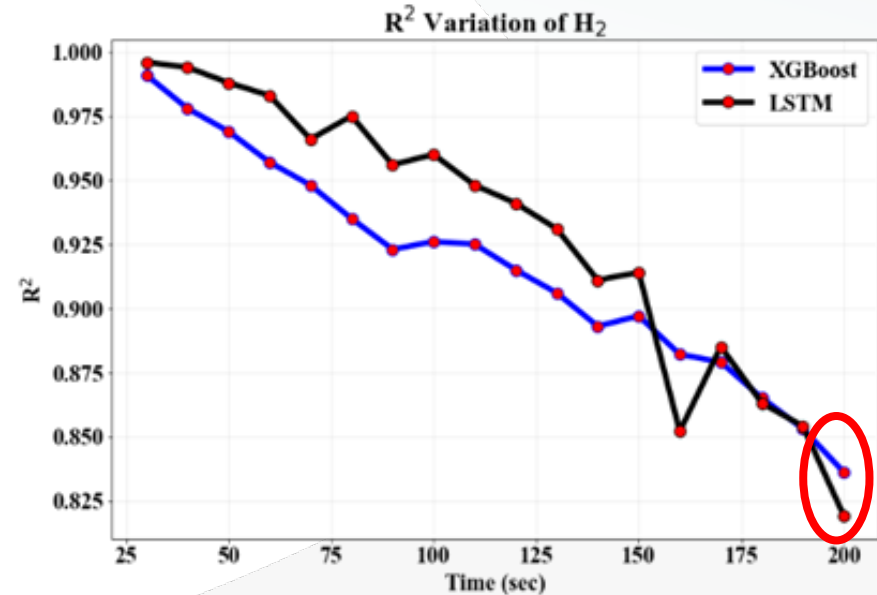
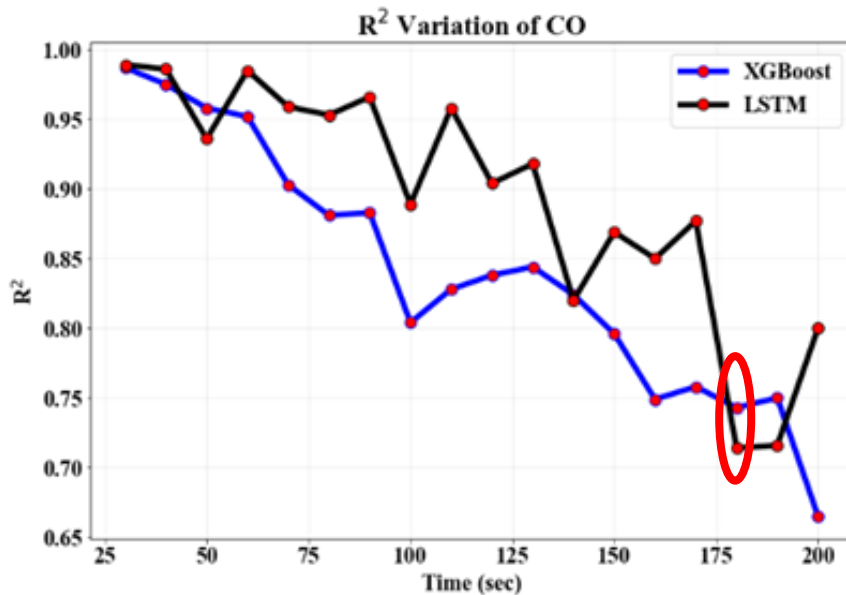
- 本研究基於先前團隊進行PKS與SS共氣化產生之數據進行機器學習，相較傳統CFD方式與Aspen Plus具更佳之效率。
- 氣化需要穩定氣源以供發電，故提前預測合成氣產量可協助調整。
- 利用LSTM與XGBoost以過去之H₂與CO數據預測未來之H₂與CO濃度。
- 預測極限以及最佳參考歷史數據時間為後續的主要探討點。



1kW_{th} 氣化爐(3/6)

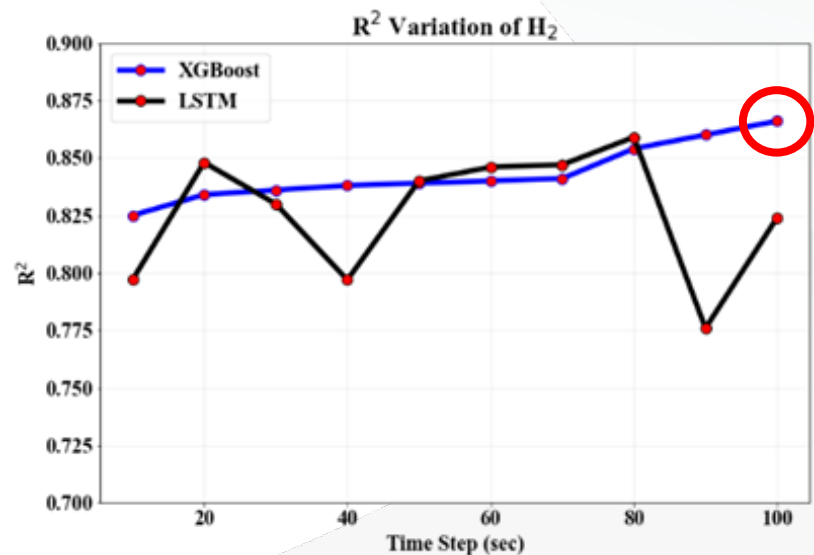
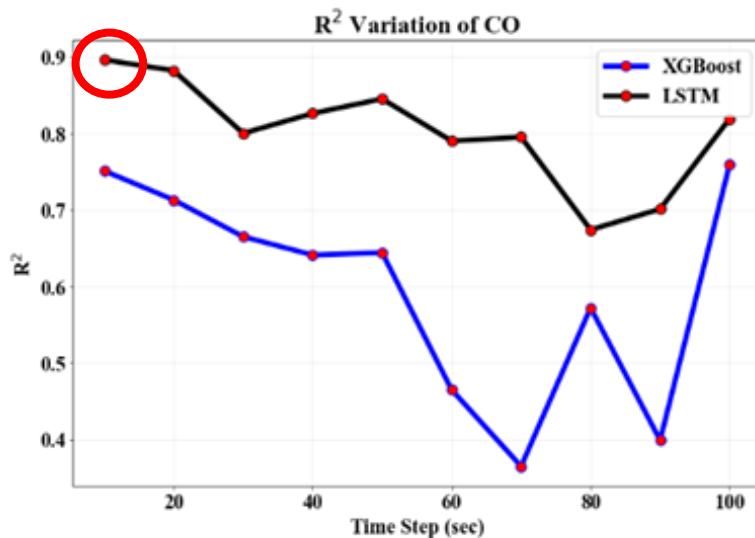
- 極限預測時間評估結果顯示 (基於30秒時間步長)

1. CO: LSTM模型對一氧化碳之預測表現較優於XGBoost，僅在幾個時間點之預測結果略差，於第180秒後模型表現較弱(R^2 低於0.8)
2. H₂: LSTM基本上皆優於XGBoost，且兩者於第200秒預測結果 R^2 皆低於0.85



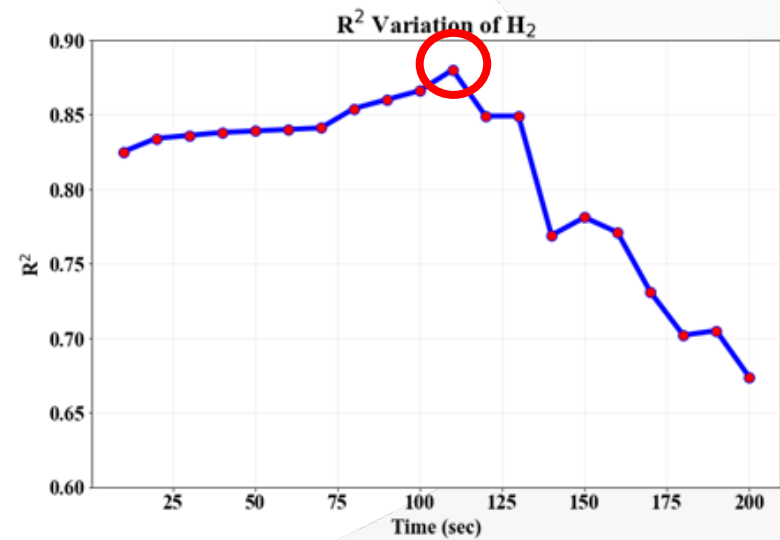
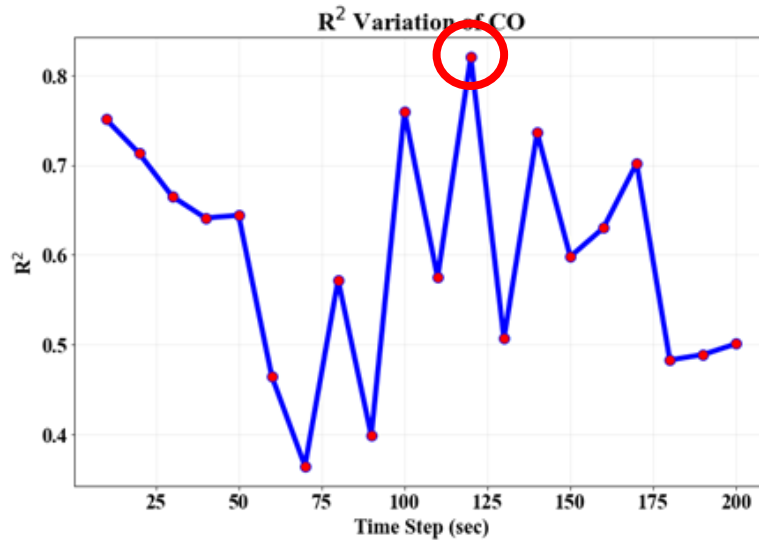
1kW_{th} 氣化爐(4/6)

- 最佳時間步長評估結果顯示 (基於200秒之未來預測)
 1. CO: 當時間步長為100秒時，兩種模型的預測準確度往上提升。當使用LSTM模型並採10秒時間步長時可達到0.896之R²值
 2. H₂: XGBoost模型的預測準確度隨著時間步長增加而提升，當時間步長為100秒時可達 0.866且優於LSTM



1kW_{th} 氣化爐 (5/6)


- XGBoost 延伸探討(基於200秒之未來預測)
 1. CO:當時間步長為120秒時， R^2 達到0.82，低於LSTM
 2. H₂:當時間步長為110秒時， R^2 達到0.88，優於LSTM



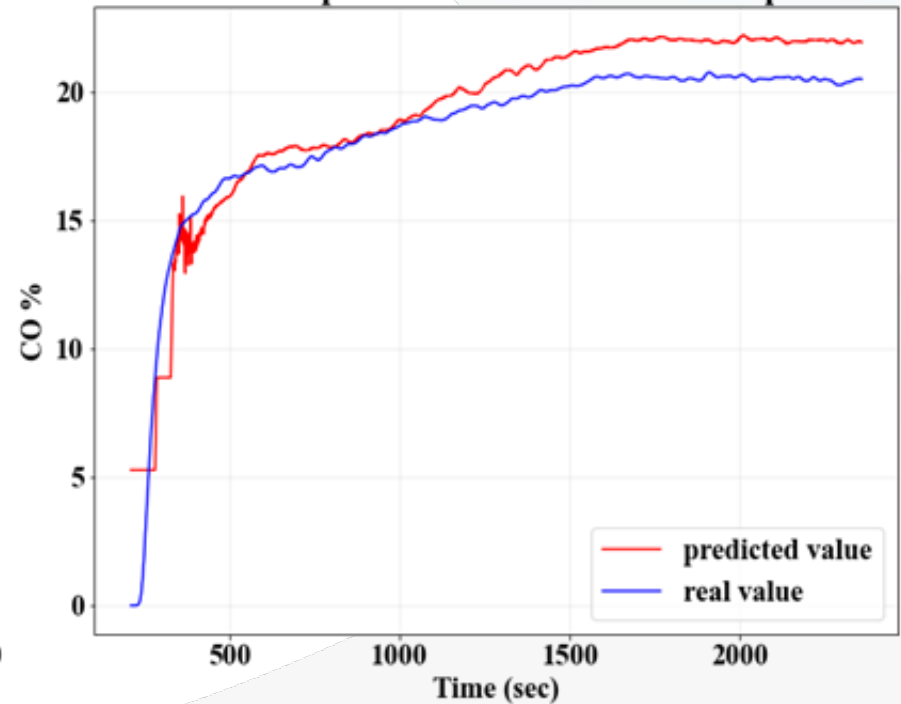
1kW_{th} 氣化爐 (6/6)

- 以 200 秒預測為目標之模型與時間步長配置如下：
 CO: LSTM、10秒時間步長
 H₂: XGBoost、110秒時間步長

200 sec prediction with 110 sec time step



200 sec prediction with 10 sec time step



Thank you for your attention

