



基於多參數連動機制的高爐操作最佳化系統

中鋼公司研發處智慧技術組（T74）研究員 / 羅凱帆
中鋼公司研發處智慧技術組（T74）研究員 / 許朝詠
中鋼公司研發處智慧技術組（T74）組長 / 黃俊奎

關鍵字：鋼鐵工業、人工智慧、深度學習、多參數

摘要

本研究以高準確度之單位鐵水用風量（Specific Production Blast Volume, SPBV）預測模型為核心，結合轉換器模型（Transformer）深度學習架構與梯度回傳最佳化技術，建立一套能預測未來 4 小時爐況走勢並提供鼓風口操作建議的智慧控制系統。有別於傳統僅針對可控參數進行數值求解的方法，本系統同步納入爐腹煤氣量、爐頂氣體成分、透氣率、理論火焰溫度等九項連動參數，透過差異化懲罰機制確保操作建議符合高爐物理耦合特性。經三種情境測試驗證，納入連動參數約束後，系統能在合理調整幅度內有效引導爐況指標趨近目標區間，且建議值符合熱平衡原理，具備實際執

行可行性，為高爐智慧化操作決策提供可靠依據。

一、前言

高爐煉鐵為現代鋼鐵生產之核心製程，其穩定運轉直接關係到鐵水品質、能源消耗及整體生產效率。由於高爐處於高溫、高壓之封閉環境，操作人員無法直接觀測內部反應，僅能仰賴外部大量量測數據推估爐內狀態。如圖 1 所示，高爐製程具備顯著的時間遲滯特性：礦料自爐頂投入至沉降至鼓風口約需 6 小時，隨後經燃燒與還原反應產出熔融鐵水則需約 2 小時。整體反應涉及氣、液、固三相流動及複雜的物理化學變化，各項參數間具高度耦合性，任何操作變數之變動皆可能在數分鐘至數小時




圖 1 高爐生產流程與各區反應滯後時間

內引發連鎖響應。傳統操作實務高度依賴人員經驗進行決策，然而在追求高精度與智慧化生產的趨勢下，經驗導向之模式已難以滿足現代化精細控制的需求。

近年來，人工智慧 (Artificial Intelligence, AI) 於鋼鐵製程之應用蓬勃發展。日本 JFE 鋼鐵 (2021) 利用卷積神經網路 (CNN) 模擬資深操作員行為 [1]，輸入鐵水溫度偏差、焦炭比及風口溫度等關鍵變數趨勢圖，產出噴煤量調控建議。結果顯示，該模型與操作員實際行動吻合度達 71%，整合至系統後可降低鐵水溫度控制達 1.3°C。2023 年，美國能源部與普渡大學針對鋼鐵業痛點，開發出整合計算流體動力學與 AI 之智能可視化高爐 (Intelligent Variable Blast Furnace, IVBF) 系統 [2]。該系統透過精準的流場與熱交換模擬，輔以高效 AI 預測演算法，將預測誤差降至 10% 以下，並達成秒級的即時決策回饋。在實務應用上，IVBF 有

效掌握爐內料層與風口噴燃料之動態變化，促成燃料成本降低 10% 並優化生產效能。同時，系統支援數位化模擬訓練，縮短人才培訓週期，為高爐操作轉型智能化奠定厚實基礎。2024 年，印度 TATA 鋼鐵開發數位孿生系統 Metafur [3]，利用機器學習作為軟感測器 (Soft Sensors)，即時預測生產力與鐵水品質。該系統整合線上優化器，針對 9 組操作變數尋找最佳設定值，成功提升 3% ~ 5% 的生產力並有效優化燃料率。

綜上所述，應用 AI 最佳化方法建立智慧化控制系統已成為提升高爐效能之關鍵手段。透過深度學習歷史爐況資料，建立具備預測能力與操作建議功能的控制模型，不僅能強化對未來爐況的預判，更能協助操作人員實現精確控溫與節能降耗之目標。

二、中鋼高爐智能化發展

中鋼公司於 2020 年二號高爐大修期間，成功將其轉型為國內首座「智慧高爐」。透過導入人工智慧物聯網 (Artificial Intelligence of Things, AIoT) 及 AI 演算法，開發出 27 項智慧模組，使高爐製程轉變為「可透視、能預知、易掌控」的智慧化生產體系。所有關鍵指標與數據均整合於「煉鐵智慧平台」，透過可視化介面協助操作人員即時掌握爐況。目前已上線的模組包含：利用影像分析進行投料前的粒徑辨識與鼓風口狀態監測、應用數據分析進行銅冷卻壁殘厚及鐵水溫度預測，以及運用異音智慧判斷輔助輸送帶巡檢等等。然而，現有模組多屬針對局部區域的分析建議，尚未能有效統整全爐反應，達成全局最佳化操作之目標。



高爐製程具備長週期的物理化學反應特徵，從入料至鐵水產出約需 8 小時，具有顯著的滯後效應。為捕捉此類長時效的時間相關性，傳統研究多採用長短期記憶模型 (LSTM)[4]。然而，隨著深度學習技術進步，Transformer 模型在處理複雜時間序列數據上展現出顯著優勢 [5]；相較於非序列性數據適合傳統機器學習模型（如隨機森林樹、支持向量機等），Transformer 具備更卓越的能力以捕捉深層的時間依賴性，惟需大量高質量數據驅動。

面對市場波動、全球減碳趨勢及製程複雜度提升，分散式的 AI 模組已難以兼顧整體運作效率。本計畫聚焦於代表生產效率的關鍵指標——單位鐵水用風量 (SPBV)，旨在開發一套「高爐 SPBV 智慧控制系統」。本系統結合 Transformer 深度學習架構與梯度回傳最佳化方法，可預測未來 4 小時之 SPBV 趨勢並提供操作建議。系統建議參數涵蓋兩大範疇：可控參數：操作人員可直接調控之數值，如富氧率與噴煤量。連動參數：隨操作變動而產生自然物理響應之數值，包含爐腹氣體量、爐頂氣體成分、透氣率及噴煤率等。

本報告將深入探討於最佳化模型中納入「連動參數」之必要性，並透過分析高爐內部的物理機制與模型輸入的一致性，論證單純調整可控參數與加入連動參數後，在預測精準度與操作建議合理性上的本質差異。

三、高爐多偶合參數智能化控制

3.1 高爐製程的參數耦合特性

高爐製程為典型的多輸入多輸出複雜系

統，其內部物理與化學反應存在高度非線性與緊密的耦合關係。為精準建立預測模型，本系統將高爐操作參數歸納為以下三個核心層次：

1. 可直接操作之「控制參數」

高爐屬高度封閉之系統，操作端點主要集中於「爐頂投料」與「鼓風口噴吹」兩處。其中，鼓風口參數對爐內熱狀態的影響最為直接且迅速。本模型選定以下兩項指標作為智能化調控的核心變數：

- 富氧率：藉由提高熱風中的純氧比例，提升燃燒強度與煤氣體積，藉此加速焦炭與噴吹煤粉的燃燒反應。
- 噴煤量：透過鼓風口噴入煤粉以替代部分焦炭。此舉能有效降低焦比並優化生產成本，但噴煤量需受限於爐內透氣性之平衡點。

2. 即時動態響應之「連動指標」

當富氧率或噴煤量變動時，爐內物理狀態將於數分鐘內產生連動響應：

- 爐腹氣體量：受富氧與噴煤直接影響。燃燒區反應氣體量的變化將直接改變爐腹氣體流量，進而影響爐料的浮力支撐與氣流透氣阻力。
- 理論火焰溫度：由富氧率、風溫及噴煤量共同定義。作為評估爐內熱評估的關鍵指標，控制參數的微調會即時反映在理論火焰溫度的波動上。
- 爐頂氣體成分：隨煤氣量與反應強度變化，爐頂產出之 CO、CO₂ 及 H₂ 含



量將產生對應位移，反映還原反應的效率。

- 透氣率：綜合反映爐料層對氣體通過的阻力。在爐料性質穩定的前提下，氣體流量的變動是影響透氣率的主要動態因子。

3. 批次配料連動之「平衡參數」

此類參數與每爐次的配料計算深度掛鉤，隨噴煤量調整而產生的規律性變動：

- 噴煤率（PCR）：每噸鐵水之耗煤量，與噴煤總量呈線性相關，為衡量噴煤操作強度的標準化指標。
- 焦炭率（CR）：每噸鐵水之焦炭消耗量。基於噴煤與焦炭的替代效應，當噴煤量增加時，焦炭率通常隨「置換比」下降，但其效率受當前爐況動態影響。
- 焦炭批重：與整體配料計畫密切相關，需隨噴煤量與焦炭率的調整進行即時修正，以維持裝料矩陣的穩定。

上述三個層次共同構成了高爐操作的物理圖像，表 1 是參數總覽。任何單一層次資訊的缺失，皆會導致對爐況理解產生盲點。本模型透過整合全層次參數，旨在克服參數間的耦合干擾，實現更精準的操作建議。

3.2 模型架構設計

本系統的核心預測模型採用 Transformer 深度學習架構，這是近年來在時序預測領域表現最為突出的模型類型之一，其優勢在於能夠有效捕捉長時間序列中各時間點之間的複雜依存關係。模型的運作流程可分為三個步驟（如架構圖所示）：

1. 第一步：讀取歷史爐況

模型以過去 8 小時（480 分鐘）的爐況資料作為輸入，涵蓋最多 65 項爐況特徵，透過 Transformer 編碼器對這段歷史資料進行深度特徵萃取，學習爐況隨時間變化的規律。

表 1 參數分層與物理意義總覽

層次	類型	參數名稱	物理意義
第一層	可控參數	富氧率	鼓入空氣含氧量
	可控參數	噴煤量	鼓風口噴入粉煤量
第二層	即時連動	爐腹氣體量	爐腹位置反應產生之氣體量
	即時連動	爐頂氣體成分	爐頂排出氣體中的CO、CO ₂ 、H ₂ 含量
	即時連動	理論火焰溫度	鼓風口前燃燒區的理論溫度
	即時連動	透氣率	氣體通過爐料層的阻力指標
第三層	批次連動	噴煤率	每噸鐵水的噴煤量
	批次連動	焦炭率	每噸鐵水的焦炭使用量
	批次連動	焦炭批重	每批次裝入的焦炭量



2. 第二步：Transformer 深度特徵萃取

輸入資料通過 2 層 Transformer 編碼器，透過自注意力機制學習 480 分鐘內各時間點之間的爐況依存關係，捕捉爐況隨時間變化的長期規律。接著以 8 組獨立的時間目標向量對時序資料進行注意力池化，讓每個查詢向量各自學習如何從歷史序列中萃取對應預測時間步最有用的資訊。

3. 第三步：同時預測未來 8 個時間點

模型一次前向計算即可輸出未來 4 小時內、每隔 30 分鐘共 8 個時間點的 SPBV 預測值，讓操作人員能掌握完整的爐況走勢，而非只看下一個時間點。

4. 第四步：基線修正

高爐是一個長期穩定生產的設備，因此生產數據大多有一穩定的趨勢，為提升預測穩定性，系統在模型預測之外，額外建立一組簡單的線性基線（以歷史 SPBV 值估算未來趨勢），模型只需學習基線無法解釋的變動部分，兩者合併後輸出最終預測結果。

本次模型使用之資料來源為中鋼二號高爐，其中訓練資料涵蓋 2023 年 11 月至 2024 年 10 月的實際高爐運作紀錄，測試資料則使用 2025 年的資料進行驗證，資料使用設定如表 2，確保模型評估結果反映真實的預測能力而非對歷史資料的記憶。

模型訓練完成後即固定參數，以可微分爐況模擬器的角色嵌入最佳化控制系



圖 2 模型架構示意圖

表 2 資料設定

項目	設定
訓練資料	2023-11-01 ~ 2024-10-15
驗證資料	2025-03-12 ~ 2025-06-16
測試資料	2025-06-16 ~ 2025-09-30
回望長度	480 分鐘
預測步數	8 步 (每步 30 分鐘)

統，透過梯度回傳協助控制器找到最佳操作建議，其預測品質直接決定操作建議的可信度。



3.3 參數最佳化方法與機制

1. 梯度回傳最佳化技術

傳統高爐操作高度依賴人工經驗，雖具實務價值，但在面對多維度參數與複雜爐況時，難以在短時間內產出系統性的優化方案，亦無法精確量化調整後的影響。本系統引入梯度回傳最佳化技術，將搜尋最佳參數的過程轉化為自動化的數學求解過程，在既定操作約束下尋找最優解。

該技術將訓練完成的預測模型視為一個可微分高爐模擬器。其核心原理是利用梯度導引參數搜尋方向：系統使用損失函數（Loss Function）計算當前預測值與目標值的差距（損失，Loss），透過預測模型每一層的可微分數學運算，將損失由輸出端反向傳遞至輸入端，藉此精確計算各操作參數（如富氧率、噴煤量）對最終目標的影響權重與調整方向。此方法無需窮舉所有參數組合，即可高效收斂至局部最佳解。

2. 損失函數設計

損失函數用於量化當前操作設定與目標狀態的偏離程度，本系統採用複合式損失函數，平衡「達成目標」與「操作穩定」兩大需求：

目標帶違反損失：採用平滑的數學形式定義損失懲罰。當預測指標超出目標區間（950 ~ 980）時，隨差距增加給予對應損失；落於目標帶內則損失為零。平滑化設計確保了梯度計算的連續性，避免優化過程出現震盪。

參數變化量懲罰：為符合現場操作穩定性，防止系統給出劇烈且具風險的調整建議，本系統對參數偏移量施加懲罰。偏移幅度越大，損失越高。對於連動參數，其懲罰強度設定為可控參數的十倍，確保其僅在符合物理邏輯的前提下進行微調。

3. 漸進式目標帶機制

考量高爐反應具備時滯性與物理慣性，爐況指標難以立即達成大幅度的跳變。若要求模型於預測初期即刻落入目標區間，將導致優化建議過於激進。本系統設計漸進式目標帶：以當前實測值為起點，目標帶上界在 4 小時（8 個時間步）的預測範圍內，線性收斂至最終目標。此機制允許近期時間步具備緩衝空間，引導參數循序漸進調整，確保優化建議符合高爐操作的實際物理特性。

4. 參數邊界與工程約束

為確保建議值具備工程可行性，系統在優化迭代過程中實施邊界截斷。參數搜尋範圍限定在歷史數據分布的 1% 至 99% 百分位數區間內。這確保了所有建議值均落在設備能力與歷史成功操作經驗所涵蓋的範圍內，避免產生數學正確但實務上不可行的「無效建議」。

5. 不確定性評估與決策參考

高爐製程具隨機性與量測誤差，本系統提供兩項指標作為決策信心參考，協助人員判斷建議方案的可靠程度：



符合預測區間：基於驗證集的歷史誤差，計算出 90% 信心水準下的預測區間。此指標直接反映模型在實務上的誤差範圍，而非單純的數學理論估計。

隨機採樣信賴值：透過在推論過程中多次隨機關閉模型的部分神經元，對同一輸入進行多次預測，觀察預測結果在不同採樣下的一致程度。若多次預測結果趨於集中，代表模型對當前爐況判斷穩定，信賴值高；反之則代表爐況特徵偏離模型已知領域，操作員應提高警覺並介入研判。




圖 3 最佳化流程示意圖

四、系統在三種情境測試

本次測試以實際高爐運作資料為基礎，模擬當爐況指標偏離目標區間時，系統能否提供合理的操作建議，引導爐況回到目標帶內。為保護實際生產數據，以下所有數值均以相對基準值的百分比偏差表示，基準值設定參考高爐正常操作之典型值，各風口參數與爐況指標均以此為標準進行標準化，而富氧率因本身即為百分比，因此只計算其增

減，不另外計算百分比偏差，部分連動參數亦不列出。

測試情境為 2025 年 5 月 23 號數據：當前爐況指標相對基準值偏高約 +3.2%，目標為在未來 4 小時內將其逐步引導至目標帶（偏差趨近於零）。測試針對三種不同的參數調整策略分別進行模擬分析，評估各策略在數值達成效果與實際操作可行性兩個面向上的表現差異。

1. 情境一：六項可控參數同時調整

第一種情境開放鼓風口六項可控參數同時進行最佳化搜尋，包含風量、風壓、風溫、濕度、富氧率與噴煤量，系統在不受物理限制的條件下，純粹以數值求解方式搜尋最佳參數組合。

測試結果顯示（表 3），系統在數值上能夠將爐況指標的偏差從 +3.2% 收斂至 +0.4%，接近目標帶。然而，仔細檢視各參數的建議調整方向與幅度，部分風口參數的建議值出現與實際操作慣例不符的情形，調整方向雖然在數學上使損失下降，但在能源效率與爐況穩定性的考量下難以實際執行，顯示純數值搜尋在缺乏物理約束的情況下，容易產生數學最優但操作上不可行的建議。

2. 情境二：僅調整富氧率與噴煤量

第二種情境縮小最佳化範圍，僅針對現場最常調控的富氧率與噴煤量兩項參數進行搜尋，其餘四項風口參數維持不變。



表 3 情境一參數調整狀況

時間步	風量 (%)	風壓 (%)	濕度 (%)	風溫 (%)	富氧率	噴煤量 (%)	SPBV (%)
T+30min	+0.15%	-1.58%	-1.60%	-0.42%	2.3	+2.13%	+2.46%
T+60min	+0.26%	-0.53%	+0.00%	-1.00%	2.2	+4.33%	+2.41%
T+90min	+0.38%	+0.53%	+2.00%	-1.58%	2.2	+6.47%	+1.78%
T+120min	+0.51%	+1.32%	+3.60%	-2.17%	2.1	+8.60%	+1.21%
T+150min	+0.62%	+2.37%	+5.60%	-2.75%	2	+10.73%	+1.03%
T+180min	+0.74%	+3.42%	+7.20%	-3.33%	1.9	+12.87%	+0.78%
T+210min	+0.87%	+4.47%	+9.20%	-3.92%	1.9	+15.07%	+0.55%
T+240min	+0.98%	+5.26%	+10.80%	-4.50%	1.8	+17.20%	+0.40%

由於可調整的自由度大幅減少，系統為了在有限變數下強行達成爐況指標下降的目標，給出了偏離基準值達數倍以上的極端建議，如表 4，遠超設備實際能力與爐況穩定性所能承受的範圍，完全不具備實際執行的可行性。此結果清楚說明，在缺乏物理合理性約束的前提下，限縮調整變數反而可能使最佳化器往更極端的方向求解，不僅無法實施，更可能對操作人員產生嚴重誤導。

3. 情境三：調整富氧率與噴煤量並納入連動參數約束

第三種情境在富氧率與噴煤量的調整基礎上，進一步納入噴煤率與焦炭率的連動約束。由於噴煤量、噴煤率與焦炭率三者之間存在高度的物理耦合關係，將其納入最佳化框架後，系統的搜尋空間受到物理合理性的隱性約束，輸出建議也更符合高爐的實際冶煉邏輯。

表 4 情境二參數調整狀況

時間步	風量 (%)	風壓 (%)	濕度 (%)	風溫 (%)	富氧率	噴煤量 (%)	SPBV (%)
T+30min	0	0	0	0	2.3	+38.33%	+1.98%
T+60min	0	0	0	0	2.2	+76.60%	+1.89%
T+90min	0	0	0	0	2.1	+114.87%	+1.22%
T+120min	0	0	0	0	2	+153.20%	+0.57%
T+150min	0	0	0	0	1.9	+191.47%	+0.37%
T+180min	0	0	0	0	1.8	+229.80%	+0.19%
T+210min	0	0	0	0	1.6	+268.07%	+0.04%
T+240min	0	0	0	0	1.5	+306.33%	+0.00%



測試結果顯示，如表 5，系統建議噴煤量從相對基準值偏差 +1.7% 溫和上升至 +13.0%，搭配富氧率調整約 -0.2，即可使爐況指標的偏差從 +3.2% 收斂至 +0.4%，累計改善幅度達 2.8 個百分點。同時，噴煤率隨噴煤量連動上升，焦炭率則對應下降，兩者的變化方向與幅度均符合高爐燃料替代的熱平衡原理，操作建議具有明確的物理依據與實際執行可行性。

三種情境的測試結果清楚驗證，單純的數值最佳化在缺乏物理約束的條件下，難以給出符合實際操作需求的建議。情境一雖能在數值上達成目標，但部分建議不符操作慣例；情境二因自由度不足而產生極端建議，完全失去參考價值；情境三透過納入連動參數約束，在確保建議值符合熱平衡原理的前提下，有效引導爐況指標趨近目標區間，是目前最具實際應用價值的參數調整策略，也為後續擴展至更多維度物理限制的全方位決策系統奠定基礎。

五、結論

高爐製程的高度耦合性是其操作複雜性的根本來源，也是智慧化控制系統設計必須正視的核心挑戰。富氧率與噴煤量作為操作員最直接的調控手段，其影響並不止步於這兩個數字本身，而是透過爐內複雜的物理化學反應，牽動從爐缸燃燒區到爐頂煤氣出口的整個爐況體系。本研究透過三種情境的系統性測試，清楚揭示了這一物理現實對智慧化控制系統設計的深遠影響。

測試結果顯示，在缺乏物理約束的條件下，無論是開放六項可控參數同時搜尋，還是僅限縮於富氧率與噴煤量兩項，系統均難以給出符合實際操作需求的建議。前者雖在數值上能使爐況指標趨近目標帶，但部分參數建議偏離操作慣例；後者則因自由度不足，迫使最佳化器給出偏離基準值數倍以上的極端建議，完全失去參考價值。唯有在情境三中，透過同步納入噴煤率與焦炭率的連動約

表 5 情境三參數調整狀況

時間步	風量 (%)	風壓 (%)	濕度 (%)	風溫 (%)	富氧率	噴煤量 (%)	PCR (%)	CR (%)	SPBV (%)
T+30min	0	0	0	0	2.4	+1.67%	-8.00%	+1.00%	+2.46%
T+60min	0	0	0	0	2.4	+3.27%	-0.60%	+0.69%	+2.41%
T+90min	0	0	0	0	2.3	+4.87%	+6.73%	+0.40%	+1.78%
T+120min	0	0	0	0	2.3	+6.47%	+14.13%	+0.11%	+1.21%
T+150min	0	0	0	0	2.3	+8.13%	+21.53%	-0.20%	+1.03%
T+180min	0	0	0	0	2.2	+9.73%	+28.87%	-0.49%	+0.78%
T+210min	0	0	0	0	2.2	+11.33%	+36.27%	-0.77%	+0.55%
T+240min	0	0	0	0	2.2	+13.00%	+43.67%	-1.09%	+0.40%



束，系統才得以在合理的調整幅度內，引導爐況指標從偏高基準值 +3.2% 平穩收斂至 +0.4%，且連動參數的變化方向與幅度均符合高爐燃料替代的熱平衡原理。此結果有力驗證了連動參數在最佳化控制框架中的不可或缺性。

本系統在最佳化控制框架中引入連動參數，正是對這一物理現實的正面回應。具體而言，連動參數的加入帶來了以下三項核心效益：

1. 維持模型輸入的物理一致性：Transformer 模型的預測能力來自對真實歷史爐況規律的學習，其可靠性的前提是推論時的輸入與訓練資料具有相近的特徵分布。納入連動參數後，最佳化過程中的輸入修改更符合高爐的物理邏輯，使模型預測建立在訓練分布的支撐之上，而非在分布邊界以外的不確定區域進行外插。
2. 提供完整且具物理意涵的操作建議：單一的富氧率與噴煤量建議值，對操作員而言是資訊不完整的。加入連動參數後，操作員能夠看到調整後整體爐況的預期走向，包括燃燒溫度、透氣性、氣體成分的變化，從而對建議的合理性形成更全面的判斷，提升實際採納建議的可行性與信心。
3. 透過差異化懲罰機制隱性約束物理合理性。對連動參數施加更高的調整懲罰，使系統在追求 SPBV 目標的同時，也自然地將連動參數的估計值限制在符合物理邏輯的範圍內，避免出現可控參數已大幅調整但爐況響應估計過於激進或失真的情形。

綜上所述，連動參數在高爐最佳化控制系統中的角色，並非增加系統複雜度的附加選項，而是確保最佳化結果在物理上可信、在操作上可用的必要組成部分。忽略連動參數的最佳化系統，本質上是在一個簡化且失真的爐況模型上求解，所給出的建議難以真正反映高爐的實際物理行為。

本系統目前已將連動參數的涵蓋範圍從噴煤率與焦炭率進一步擴展，同步納入理論火焰溫度、爐腹煤氣量、爐頂氣體成分（CO、CO₂、H₂）、透氣率及焦炭批重等共九項連動參數，形成涵蓋即時爐況響應與批次配料計算的完整多維度約束框架。這確保模型所提出的最佳化參數，不僅能達成 SPBV 的控制目標，更能全盤兼顧爐內的物理反應實境與操作安全。未來將持續評估系統在不同爐況條件下的建議穩定性，並進一步強化連動參數估計的精確度，以實現真正可落地執行的全方位智慧化決策輔助系統。

參考文獻

1. Yoshinari Hashimoto et al., 'An Operator Behavior Model for Thermal Control of Blast Furnace', ISIJ International, Vol. 62, No. 1, pp. 157-164, 2022.
2. Tyamo Okosun, 'Integrated Virtual Blast Furnace for Real-Time Energy Efficiency Improvement| IEDO', AMMTO & IEDO JOINT PEER REVIEW, May, 2023.
3. Sri Harsha Nistala et al., 'metafur: Digital Twin System of a Blast Furnace', Trans Indian Inst Met, Vol. 77, No. 12, pp. 4383-4393, 2024.
4. 羅凱帆 等人，'高爐鐵水溫度之特徵時間性分析與預測模型建立'，中國鑛冶工程學會，台灣，109 年。
5. Kendai Itakura et al., 'Benchmarking a Wide Range of Unsupervised Learning Methods for Detecting Anomaly in Blast Furnace', ICPRAM 2024, pages 641-650, 2024.