

DỰ BÁO VÀ TỐI ƯU HÓA ĐIỆN NĂNG TIÊU THỤ TRONG CÔNG NGHIỆP NẶNG ỨNG DỤNG HỌC MÁY

LÊ THỊ KIM NGỌC^{1*} - NGUYỄN PHƯƠNG LINH²
- VÕ PHƯƠNG HÀ³ - VÕ QUANG THIÊN⁴ - CÔNG THÀNH VINH⁵

*Tác giả liên hệ - Email: kimngoc3101@gmail.com

Ngày nhận bài: 12/8/2026

Ngày sửa bài: 28/8/2026

Ngày duyệt đăng bài: 14/9/2026

Tóm tắt:

Nghiên cứu đề xuất quy trình tích hợp giữa dự báo phụ tải đa khoảng thời gian (15 phút, 1 giờ, 24 giờ) và tối ưu hóa dịch chuyển phụ tải cho nhà máy DAEWOO Steel nhằm loại bỏ triệt để rò rỉ dữ liệu theo thời gian. Tập đặc trưng được thiết kế nghiêm ngặt từ dữ liệu lịch sử khả dụng tại mốc dự báo để so sánh các mô hình học máy (Random Forest, XGBoost, LSTM và mô hình lai hai tầng). Phương pháp Conformalized Quantile Regression (CQR) được tích hợp để lượng hóa độ bất định qua khoảng dự báo P10-P90 hiệu chỉnh. Dự báo trước 24 giờ sau đó được đưa vào mô hình Quy hoạch tuyến tính nhằm phân bổ phụ tải linh hoạt, giảm chi phí và hạ phụ tải đỉnh. Thực nghiệm chỉ ra sai số tăng dần theo horizon (MAE từ 2,690 kWh ở 15 phút lên ~8,000 kWh ở 24 giờ); mô hình lai tối ưu ở khoảng ngắn nhờ phân loại tốt chế độ vận hành, trong khi mô hình phân vị P50 dẫn đầu ở mốc 24 giờ. Kết quả khẳng định tính khả dụng của đặc trưng đầu vào và đánh giá đa khoảng thời gian là cốt lõi cho điều độ năng lượng.

Từ khóa: dự báo phụ tải điện, sản xuất thép, dự báo đa khoảng thời gian, rò rỉ dữ liệu, định lượng bất định, tối ưu dịch chuyển phụ tải, quản lý năng lượng công nghiệp

Machine learning-based energy consumption forecasting and optimization in heavy manufacturing

Abstract:

This study presents an integrated framework combining multi-horizon load forecasting (15-minute, 1-hour, and 24-hour) with load-shifting optimization for the DAEWOO Steel plant, explicitly eliminating temporal data leakage. Leakage-safe features derived strictly from historical data available at prediction time are used to benchmark Random Forest, XGBoost, LSTM, and a two-stage hybrid architecture. Calibrated P10-P90 prediction intervals via Conformalized Quantile Regression (CQR) quantify operational uncertainty, while 24-hour day-ahead forecasts are embedded into a Linear Programming model to optimize flexible load shifting for peak reduction and cost savings. The results indicate that errors scale with the forecast horizon (MAE from 2.690 kWh at 15 minutes to approximately 8,000 kWh at 24 hours). The two-stage hybrid model excels at short horizons via regime classification, whereas the P50 quantile regression performs best at 24 hours. The findings confirm that input data availability and multi-horizon evaluation are critical for practical industrial energy management.

Keywords: power load forecasting, steel manufacturing, multi-horizon forecasting, data leakage, uncertainty quantification, load-shifting optimization, industrial energy management.

1. Đặt vấn đề

Ngành Sắt thép chiếm khoảng 7% phát thải CO₂ của hệ thống năng lượng toàn cầu, tỷ lệ này tăng lên khoảng 10% nếu tính cả phát thải gián tiếp từ ngành điện, chủ yếu do luyện kim và cán thép sử dụng nhiều điện năng (IEA, 2020). Trước áp lực giá điện biến động và cam kết giảm phát thải, quản lý hiệu quả điện năng tiêu thụ đã trở thành yêu cầu vận hành cấp thiết đối với nhà máy thép.

Học máy được xem là một phương pháp phù hợp để dự báo mức tiêu thụ điện nhờ khả năng mô hình hóa các mối quan hệ phi tuyến giữa đặc điểm vận hành và nhu cầu điện năng. Tuy nhiên, việc ứng dụng trong thực tế vẫn tiềm ẩn 4 rủi ro phương pháp luận thường bị bỏ qua: rò rỉ dữ liệu theo thời gian khi dùng các biến đo đồng thời với thời điểm cần dự báo; thiếu khung đánh giá nhất quán cho nhiều horizon; thiếu định lượng độ bất định; và thiếu kết nối giữa dự báo với một quyết định vận hành cụ thể.

Nghiên cứu sử dụng bộ dữ liệu Steel Industry Energy Consumption, thu thập qua hệ thống giám sát dựa trên nền tảng đám mây của DAEWOO Steel Co., Ltd. (Hàn Quốc), gồm 35.040 quan sát chu kỳ 15 phút trong năm 2018 (V. E. Sathishkumar et al, 2021; W. T. Al-Shaibani, et al, 2023). Từ đó, nghiên cứu đề xuất một khung dự báo điện năng tiêu thụ đa horizon (15 phút, 1 giờ, 24 giờ), tuân thủ nghiêm ngặt nguyên tắc tránh rò rỉ dữ liệu, đồng thời gắn kết dự báo với định lượng độ bất định và một bài toán ra quyết định vận hành cụ thể, nhằm phản ánh đúng năng lực dự báo có thể triển khai trong thực tế.

2. Tổng quan nghiên cứu


Nhiều công bố trên cùng bộ dữ liệu dùng trực tiếp các đại lượng điện đo đồng thời với biến mục tiêu - CO₂, công suất phản kháng, hệ số công suất - làm đặc trưng đầu vào, đạt hệ số xác định R² gần như tuyệt đối ($\geq 0,99$) (Bernardo-Sánchez, 2026; N. Adar et al, 2026)); một nghiên cứu khác cũng dùng cùng tập đặc trưng này (bao gồm CO₂, công suất phản kháng, hệ số công suất) với mô hình học sâu LSTM/GRU, đánh giá bằng MAE/RMSE thay vì R².

3. Phương pháp nghiên cứu

3.1. Khung nghiên cứu tổng thể

Nghiên cứu đề xuất một quy trình tích hợp giữa dự báo điện năng tiêu thụ bằng học máy và tối ưu hóa dịch chuyển phụ tải trong môi trường sản xuất công nghiệp nặng. Quy trình nghiên cứu gồm 2 giai đoạn chính: (1) xây dựng và đánh giá các mô hình dự báo điện năng tiêu thụ ở nhiều khoảng thời gian; và (2) sử dụng kết quả dự báo trước một ngày làm đầu vào cho bài toán tối ưu hóa phụ tải nhằm đánh giá khả năng giảm chi phí điện và hạn chế phụ tải đỉnh.

Hình 1. Quy trình nghiên cứu tổng thể



Nghiên cứu xem xét 3 khoảng dự báo: $H = \{1, 4, 96\}$, tương ứng với 15 phút, 1 giờ và 24 giờ trên dữ liệu có chu kỳ 15 phút. Hai cấu hình đầu vào được xây dựng để đánh giá vai trò của thông tin vận hành, trong đó Cấu hình B bổ sung Load_Type với giả định trạng thái tải được biết trước. Kết quả dự báo 24 giờ được sử dụng làm đầu vào cho bài toán tối ưu hóa dịch chuyển phụ tải.

3.2. Bộ dữ liệu và phân tích dữ liệu ban đầu

Nghiên cứu sử dụng bộ dữ liệu Steel Industry Energy Consumption từ UCI học máy Repository, gồm 35.040 quan sát và 11 biến, được ghi nhận tại một cơ sở sản xuất thép ở Hàn Quốc trong năm 2018 với

chu kỳ 15 phút. Biến mục tiêu Usage_kWh biểu thị điện năng tiêu thụ tại mỗi khoảng thời gian. Dữ liệu không có giá trị thiếu, timestamp trùng lặp hoặc khoảng thời gian bị gián đoạn; một quan sát có mức tiêu thụ bằng 0 được giữ lại do không có bằng chứng về lỗi đo lường.

Phân tích ban đầu cho thấy, Usage_kWh có phân phối lệch và sự khác biệt rõ giữa các trạng thái tải. Mức tiêu thụ cũng thể hiện tính chu kỳ theo thời gian và duy trì tương quan tại độ trễ 24 giờ và 7 ngày, tạo cơ sở cho việc xây dựng các đặc trưng thời gian và đặc trưng trễ.

3.3. Tiền xử lý dữ liệu

Dữ liệu được chuyển sang định dạng thời gian, sắp xếp theo thứ tự tăng dần và kiểm tra tính liên tục theo chu kỳ 15 phút. Các đại lượng điện được ghi nhận đồng thời với biến mục tiêu và NSM được loại khỏi cấu hình dự báo chính nhằm bảo đảm tính khả dụng của thông tin tại thời điểm dự báo. Từ timestamp, các đặc trưng thời gian được trích xuất và mã hóa tuần hoàn bằng:

$$z_{sin} = \sin\left(2\pi \frac{z}{P}\right) \quad (1)$$

$$z_{cos} = \cos\left(2\pi \frac{z}{P}\right) \quad (2)$$

trong đó z là giá trị của biến thời gian và P là chu kỳ tương ứng. Do độ trễ lớn nhất là 7 ngày (672 bước), 672 quan sát đầu tiên được loại bỏ, còn 34.368 quan sát.

Dữ liệu sau đó được chia theo thứ tự thời gian, không xáo trộn ngẫu nhiên:

Bảng 1. Phân chia dữ liệu theo thời gian

Tập dữ liệu	Khoảng thời gian	Số quan sát
Huấn luyện	08/01/2018 - 30/09/2018	25.536
Xác thực	01/10/2018 - 30/11/2018	5.856
Kiểm thử	01/12/2018 - 31/12/2018	2.976

3.4. Xây dựng đặc trưng và thiết kế dự báo tránh rò rỉ dữ liệu

Nghiên cứu xây dựng bài toán dự báo tại 3 khoảng thời gian gồm 15 phút, 1 giờ và 24 giờ, tương ứng với $H=1, H=4$ và $H=96$ bước thời gian. Tập đặc trưng được xây dựng riêng cho từng khoảng dự báo nhằm bảo đảm chỉ sử dụng thông tin có thể biết tại thời điểm đưa ra dự báo.

3.4.1. Đặc trưng theo khoảng dự báo

Đối với giá trị cần dự báo y_t , đặc trưng trễ tại thời điểm t được xác định bởi:

$$L_{t,k} = y_t - k \quad (3)$$

trong đó k là số bước thời gian lùi về quá khứ. Để bảo đảm chỉ sử dụng thông tin có sẵn tại thời điểm đưa ra dự báo, một đặc trưng trễ chỉ được sử dụng khi:

$$k \geq H \quad (4)$$

trong đó H là khoảng dự báo tính theo số bước 15 phút. Theo nguyên tắc này, các lag được sử dụng như sau:

Ngoài các lag đơn lẻ, nghiên cứu xây dựng các thống kê trượt (rolling statistics) gồm trung bình và độ lệch chuẩn trong 1 giờ; trung bình, độ lệch chuẩn, giá trị lớn nhất và nhỏ nhất trong 24 giờ. Các cửa sổ được dịch lùi theo H trước khi tính toán để chỉ sử dụng dữ liệu đã quan sát được.

Để khai thác tính chu kỳ theo ngày, các đặc trưng thống kê tại cùng thời điểm trong ngày của 7 ngày trước đó cũng được xây dựng, bao gồm trung bình, trung vị, độ lệch chuẩn và giá trị lớn nhất.

3.4.2. 2 cấu hình đầu vào

2 cấu hình đặc trưng được xây dựng để đánh giá vai trò của thông tin vận hành: (1) cấu hình A: sử dụng

các đặc trưng thời gian và thông tin tiêu thụ điện trong quá khứ; (2) cấu hình B: sử dụng toàn bộ đặc trưng của Cấu hình A và bổ sung Load_Type, với giả định trạng thái tải được biết trước từ kế hoạch sản xuất.

3.5. Các mô hình dự báo điện năng tiêu thụ

Nghiên cứu triển khai 3 nhóm mô hình dự báo. Nhóm mô hình cơ sở gồm I persistence, sử dụng quan sát gần nhất còn hợp lệ tại thời điểm bắt đầu dự báo, cùng seasonal I theo ngày và theo tuần; 2 mô hình theo mùa vụ được bổ sung do chuỗi vẫn còn tự tương quan đáng kể tại độ trễ 24 giờ và 7 ngày. Nhóm thứ hai gồm Hồi quy tuyến tính, Random Forest và XGBoost. Nhóm thứ ba là mô hình lai 2 tầng, được thiết kế dựa trên đặc điểm phân phối 2 đỉnh của Usage_kWh. Do vùng giữa 2 đỉnh có mật độ quan sát thấp, một mô hình hồi quy duy nhất có thể gặp khó khăn tại các thời điểm chuyển đổi trạng thái. Dự báo cuối cùng được tính dưới dạng:

$$\hat{y}_t = p_t \hat{y}_{t,sản xuất} + (1 - p_t) \hat{y}_{t,tải thấp} \quad (5)$$

Cuối cùng, mạng Long Short-Term Memory (LSTM) được triển khai nhằm đối chiếu giữa phương pháp sử dụng các đặc trưng được xây dựng thủ công và phương pháp học trực tiếp từ chuỗi thời gian. Toàn bộ mô hình được triển khai bằng Python. Hồi quy tuyến tính và Random Forest sử dụng thư viện scikit-learn; XGBoost và các mô hình hồi quy phân vị sử dụng thư viện xgboost; LSTM được xây dựng bằng PyTorch; bước tối ưu hóa ở mục 1.9 sử dụng scipy.optimize.

3.6. Huấn luyện và lựa chọn siêu tham số

Dữ liệu được chia theo thứ tự thời gian và không xáo trộn ngẫu nhiên. Siêu tham số được lựa chọn bằng tìm kiếm theo lưới trên tập xác thực với MAE làm tiêu chí. Sau khi lựa chọn siêu tham số, các mô hình được huấn luyện lại trên dữ liệu kết hợp từ tập huấn luyện và tập xác thực, sau đó được sử dụng để dự báo trên tập kiểm thử.

Toàn bộ quá trình sử dụng giá trị khởi tạo ngẫu nhiên cố định nhằm tăng khả năng tái lập kết quả. Nghiên cứu đồng thời thực hiện bước kiểm chứng độc lập bằng cách tính lại các đặc trưng trực tiếp từ chuỗi Usage_kWh gốc, nhằm xác nhận mọi thông tin được sử dụng cho dự báo tại thời điểm t đều nằm tại hoặc trước thời điểm. Bước kiểm tra này giúp phát hiện và hạn chế rò rỉ dữ liệu theo thời gian (temporal data leakage) trong quá trình xây dựng mô hình.

3.7. Dự báo xác suất và định lượng độ bất định

Bên cạnh dự báo điểm, nghiên cứu bổ sung dự báo xác suất nhằm biểu diễn mức độ bất định của kết quả dự báo, đặc biệt đối với khoảng dự báo dài. Phương pháp hồi quy phân vị (Quantile Regression) với XGBoost được sử dụng để ước lượng 3 phân vị P_{10} , P_{50} , P_{90} thông qua hàm mất mát phân vị (pinball loss). Các phân vị dự báo được sắp xếp theo thứ tự không giảm để xử lý trường hợp các phân vị giao nhau (quantile crossing).

Khoảng dự báo thu được theo cách trên thường hẹp hơn mức cần thiết, nên nghiên cứu hiệu chỉnh lại bằng Conformalized Quantile Regression (CQR). Các mô hình phân vị chỉ huấn luyện trên tập huấn luyện, còn tập xác thực giữ vai trò tập hiệu chỉnh. Với mỗi quan sát I trong tập hiệu chỉnh:

$$\begin{aligned} E_i &= \max(P_{10}(x_i) - y_i, y_i - P_{90}(x_i)) \\ E^* &= Q_{1-\alpha}(\{E_i\}) \\ C(x) &= [\max(P_{10}(x) - E^*, 0), P_{90}(x) + E^*] \end{aligned} \quad (6)$$

Ở đây E^* là mức nói rộng, lấy tại phân vị $1 - \alpha$ của các điểm không phù hợp, còn $C(x)$ là khoảng sau khi đã nói. Cận dưới giữ ở 0 vì điện năng tiêu thụ không nhận giá trị âm.

3.8. Các chỉ số đánh giá

Hiệu năng của các mô hình dự báo được đánh giá trên tập kiểm thử bằng các chỉ số MAE, RMSE, sMAPE, MASE và R^2 . Trong đó, MAE là chỉ số chính để so sánh mô hình; các chỉ số còn lại cung cấp đánh giá bổ sung về sai số lớn, sai số tương đối, khả năng giải thích biến thiên và hiệu quả so với phương pháp

tham chiếu. Trong đó, y_i , $\hat{y}_i$, y lần lượt là giá trị thực tế, giá trị dự báo và giá trị trung bình và n là số quan sát trong tập đánh giá. $MAPE$ được tính để tham khảo nhưng không dùng làm tiêu chí chính do nhạy với các giá trị gần 0.

3.9. Tối ưu hóa dịch chuyển phụ tải dựa trên kết quả dự báo

Dự báo 24 giờ được sử dụng làm đầu vào cho bài toán tối ưu hóa dịch chuyển phụ tải. Giả sử tỷ lệ α của điện năng có thể dịch chuyển giữa các khoảng thời gian, phụ tải nền dự báo được xác định bởi:

$$\hat{b}_t = (1 - \alpha) \hat{y}_t \quad (7)$$

Gọi x_t là điện năng linh hoạt được phân bổ vào thời điểm t , p_t là mức giá điện và C là giới hạn tải. Bài toán tối ưu hóa tuyến tính được xây dựng:

$$\min_{x_t} \sum_t p_t (\hat{b}_t + x_t) \quad (8)$$

với:

$$\sum_t x_t = E_{linh\ hoat} \quad (9)$$

$$0 \leq x_t \leq C - \hat{b}_t \quad (10)$$

trong đó $E_{linh\ hoat}$ là tổng điện năng có thể dịch chuyển.

4. Kết quả nghiên cứu

4.1. Hiệu quả dự báo theo khoảng dự báo

Sai số dự báo gia tăng có hệ thống khi khoảng dự báo kéo dài do lượng thông tin khả dụng suy giảm. Ở khoảng ngắn (15 phút, 1 giờ), mô hình khai thác hiệu quả tính liên tục của chuỗi thời gian và các quan sát gần nhất. Ngược lại, ở bài toán 24 giờ (96 bước dùng chung một mốc dự báo), sai số tăng đáng kể do không còn các quan sát tức thời. Đáng chú ý, thứ hạng mô hình thay đổi rõ rệt: mô hình lai dẫn đầu ở khoảng ngắn nhưng không giữ được ưu thế ở 24 giờ, nhường vị trí tối ưu cho mô hình hồi quy phân vị P50.

4.2. Ảnh hưởng của khả năng nhận diện chế độ vận hành

Lợi ích của mô hình lai 2 tầng phụ thuộc trực tiếp vào độ chính xác của bộ phân loại chế độ vận hành. Bảng 6 tổng hợp hiệu năng phân loại và so sánh sai số giữa mô hình lai và XGBoost đơn lẻ.

Bảng 2. Đánh giá bộ phân loại và so sánh mô hình lai với XGBoost

Khoảng dự báo	Độ chính xác phân loại	MAE Mô hình lai (kWh)	MAE XGBoost (kWh)
15 phút	≈99,0%	2,690	2,785
1 giờ	≈96,7%	4,359	4,512
24 giờ	≈87,0%	9,521	8,214

Ở khoảng ngắn, trạng thái vận hành có tính liên tục cao giúp bộ phân loại đạt độ chính xác gần như tuyệt đối, từ đó giúp mô hình lai cải thiện sai số 3-5% so với XGBoost. Ngược lại, ở 24 giờ, độ chính xác phân loại giảm xuống ~87% (tương đương baseline chu kỳ tuần). Phân loại sai dẫn đến việc áp dụng sai mô hình hồi quy nhánh, làm tăng sai số đáng kể.

4.3. Dự báo xác suất: tỷ lệ bao phủ và độ rộng khoảng dự báo

Phương pháp CQR giúp cải thiện độ phủ thực nghiệm của khoảng dự báo P10-P90 tiến gần mức danh nghĩa 80%. Độ rộng khoảng dự báo mở rộng mạnh theo horizon (từ ~10,2 kWh lên >26 kWh ở 24 giờ). Việc khoảng dự báo quá rộng ở mốc 24 giờ phản ánh mức độ bất định lớn khi dự báo xa, khiến thông tin định lượng bị suy giảm dù tỷ lệ bao phủ đạt chuẩn. Phân tích này bổ sung cho quan sát [15] về sự suy giảm độ phủ ở các vùng tải đỉnh, đồng thời khẳng định giới hạn của dự báo ngày hôm sau không thể được mô tả đầy đủ chỉ bằng một chỉ số sai số trung bình đơn lẻ.

5. Kết luận

Nghiên cứu này đã hoàn thiện một khung phương pháp luận tích hợp giữa dự báo điện năng tiêu thụ đa horizon và tối ưu hóa dịch chuyển phụ tải cho ngành sản xuất thép công nghiệp nặng. Kết quả thực nghiệm khẳng định sai số dự báo gia tăng có hệ thống khi khoảng dự báo kéo dài, kéo theo sự thay đổi về kiến trúc mô hình tối ưu. Cụ thể, mô hình lai hai tầng thể hiện sự vượt trội ở các horizon ngắn hạn nhờ khả năng phân loại chính xác trạng thái vận hành mang tính liên tục. Nghiên cứu cũng chỉ ra rằng việc suy diễn kế hoạch sản xuất từ thời gian lịch không mang lại nhiều cải thiện, và phương CQR cho thấy độ bất định mở rộng đáng kể ở bài toán ngày hôm sau. Đáng chú ý, việc đưa dự báo vào mô hình Quy hoạch tuyến tính chứng minh rằng độ chính xác dự báo chỉ thực sự chuyển hóa thành lợi ích kinh tế khi kết hợp với cơ chế biểu giá công suất đỉnh và dự địa phụ tải linh hoạt phù hợp.

Từ các phát hiện trên, nghiên cứu kiến nghị các cơ sở công nghiệp nên ưu tiên tích hợp trực tiếp dữ liệu kế hoạch sản xuất từ hệ thống MES/ERP vào mô hình thay vì dùng các biến thời gian tĩnh, đồng thời sử dụng các khoảng dự báo xác suất để quản trị rủi ro vượt công suất đỉnh. Hướng nghiên cứu tương lai cần tập trung cải thiện thuật toán nhận diện chế độ vận hành dài hạn, đánh giá độ bao phủ có điều kiện tại phân đoạn tải đỉnh, và nhúng trực tiếp các khoảng dự báo CQR vào các bài toán tối ưu hóa ngẫu nhiên nhằm tối đa hóa độ tin cậy trong điều độ năng lượng ■

TÀI LIỆU THAM KHẢO:

- N. Adar et al (2026). "Energy consumption prediction using deep learning: A case study on small-scale smart steel industry," in AI and Digital Transformation: Opportunities, Challenges, and Emerging Threats in Technology, Business, and Security, Communications in Computer and Information Science, vol. 2670, Cham, Switzerland: Springer.
- P. J. García-Nieto et al (2025). "Interpretable machine learning models for estimating electric energy consumption in steel industries," Mathematics, vol. 13, no. 21, Art. No. 3364, 2025, doi: 10.3390/math13213364.
- V.E.Sathishkumaret al (2021). "Efficient energy consumption prediction model for a data analytic-enabled industry building in a smart city," Building Research & Information, vol. 49, no. 1, pp. 127-143, doi: 10.1080/09613218.2020.1809983.
- W. T. Al-Shaibani et al (2023). "Power consumption prediction for steel industry," arXiv preprint arXiv:2307.07597.

Thông tin tác giả:

LÊ THỊ KIM NGỌC^{1*} - NGUYỄN PHƯƠNG LINH²

- VÕ PHƯƠNG HÀ³ - VÕ QUANG THIÊN⁴ - CÔNG THÀNH VINH⁵

¹Đại học London

University of London

*E-mail: kimngoc3101@gmail.com

²Trường Đại học Ngoại thương

Foreign Trade University

E-mail: phuonglinhnguyen875@gmail.com

³Trường Đại học Ngoại thương

Foreign Trade University

E-mail: ha.vph03@gmail.com

⁴Đại học Kinh tế TP. Hồ Chí Minh

University of Economics Ho Chi Minh City (UEH)

E-mail: quangthien.vo.1001@gmail.com

⁵Trường THPT Chuyên Hà Nội - Amsterdam

Hanoi-Amsterdam High School for the Gifted

E-mail: cvinh02109@gmail.com