

پیش‌بینی بار و مدیریت انرژی در شبکه هوشمند با استفاده از Machine Learning

چکیده

گسترش منابع انرژی تجدیدپذیر، تولید پراکنده، خودروهای برقی، سامانه‌های ذخیره‌سازی انرژی و کنتورهای هوشمند، ساختار سنتی شبکه‌های قدرت را به سمت شبکه‌های هوشمند سوق داده است. در این شرایط، پیش‌بینی دقیق بار الکتریکی به یکی از مهم‌ترین الزامات بهره‌برداری اقتصادی، پایدار و مطمئن از شبکه تبدیل شده است. روش‌های سنتی پیش‌بینی بار، به‌ویژه مدل‌های آماری، در بسیاری از کاربردها مفید هستند؛ اما پیچیدگی روابط میان بار، شرایط آب‌وهوایی، زمان، رفتار مصرف‌کنندگان و وضعیت منابع تولید باعث شده است روش‌های مبتنی بر **Machine Learning** و **Deep Learning** مورد توجه گسترده قرار گیرند.

در این مقاله، کاربرد **Machine Learning** در پیش‌بینی بار و مدیریت انرژی شبکه هوشمند بررسی می‌شود. ابتدا مفهوم شبکه هوشمند و پیش‌بینی بار تشریح شده و سپس الگوریتم‌هایی مانند **Regression**، **Support Vector Machine**، **Random Forest**، **Gradient Boosting** و **Artificial Neural Network** و **Long Short-Term Memory** بررسی می‌شوند. همچنین نقش داده‌های تاریخی، اطلاعات هواشناسی و داده‌های کنتورهای هوشمند در آموزش مدل‌ها مورد بحث قرار می‌گیرد. در ادامه، نحوه استفاده از خروجی پیش‌بینی برای مدیریت انرژی، **Demand Response**، کنترل باتری و ادغام منابع تجدیدپذیر بررسی می‌شود. در نهایت، چالش‌هایی مانند کیفیت داده، عدم قطعیت، تغییر رفتار مصرف‌کننده، امنیت اطلاعات و تفسیرپذیری مدل‌ها مطرح شده و مسیرهای آینده پژوهش در این حوزه معرفی می‌شوند.

واژگان کلیدی: شبکه هوشمند، پیش‌بینی بار، **Machine Learning**، **Deep Learning**، مدیریت انرژی، **Demand Response**، انرژی تجدیدپذیر، سیستم قدرت.

۱. مقدمه

سیستم‌های قدرت از مهم‌ترین زیرساخت‌های هر کشور محسوب می‌شوند و عملکرد صحیح آن‌ها تأثیر مستقیمی بر فعالیت‌های صنعتی، تجاری، خانگی و خدمات عمومی دارد. یکی از وظایف اساسی در بهره‌برداری از سیستم قدرت، ایجاد تعادل میان تولید و مصرف برق است. از آنجا که انرژی الکتریکی در مقیاس شبکه به‌صورت گسترده قابل ذخیره‌سازی نیست، اپراتور شبکه باید تولید را در هر لحظه با تقاضای مصرف‌کنندگان هماهنگ کند.

در شبکه‌های سنتی، جریان اطلاعات عمدتاً یک‌طرفه بوده و مصرف‌کننده نقش محدودی در مدیریت شبکه داشته است. در مقابل، شبکه هوشمند با استفاده از زیرساخت‌های اندازه‌گیری، ارتباطات و پردازش داده، امکان تعامل دوسویه میان شبکه و مصرف‌کننده را فراهم می‌کند. توسعه کنتورهای هوشمند و زیرساخت اندازه‌گیری پیشرفته نیز حجم زیادی از داده‌های مصرف را ایجاد کرده است.

این حجم داده فرصت مناسبی برای استفاده از Machine Learning ایجاد می‌کند. برخلاف بسیاری از مدل‌های کلاسیک که به روابط از پیش تعریف‌شده میان متغیرها متکی هستند، مدل‌های Machine Learning می‌توانند الگوهای پیچیده و غیرخطی موجود در داده‌ها را استخراج کنند.

اهمیت این موضوع زمانی بیشتر می‌شود که سهم منابع تجدیدپذیر افزایش یابد. تولید انرژی خورشیدی و بادی تابع شرایط جوی است و در نتیجه، عدم قطعیت بیشتری وارد سیستم قدرت می‌شود. گزارش‌های آژانس بین‌المللی انرژی نیز بر اهمیت انعطاف‌پذیری شبکه و مدیریت تقاضا در سیستم‌های برق آینده تأکید دارند. (IEA, ۲۰۲۶)

بر این اساس، پیش‌بینی بار با Machine Learning می‌تواند به‌عنوان یکی از لایه‌های هوشمند تصمیم‌گیری در شبکه قدرت عمل کند.

۲. شبکه هوشمند و مدیریت انرژی

شبکه هوشمند یا Smart Grid نسل پیشرفته سیستم قدرت است که زیرساخت الکتریکی را با فناوری‌های ارتباطی، اندازه‌گیری و محاسباتی ترکیب می‌کند.

مهم‌ترین اجزای شبکه هوشمند عبارت‌اند از:

- Smart Meter
- Advanced Metering Infrastructure (AMI)
- SCADA
- Phasor Measurement Unit (PMU)
- منابع انرژی تجدیدپذیر
- Distributed Generation
- سیستم‌های ذخیره‌سازی انرژی
- خودروهای برقی
- تجهیزات مدیریت انرژی ساختمان
- سامانه‌های Demand Response
- سیستم مدیریت انرژی یا EMS

هدف مدیریت انرژی، استفاده بهینه از منابع موجود برای تأمین نیاز مصرف‌کنندگان با کمترین هزینه و بیشترین قابلیت اطمینان است.

برای مثال، یک سیستم مدیریت انرژی در یک ریزشبکه ممکن است تصمیم بگیرد که در ساعات دارای قیمت بالای برق، از باتری استفاده شود و در ساعات کم‌قیمت، باتری شارژ شود. برای اتخاذ چنین تصمیمی، دانستن وضعیت آینده بار اهمیت زیادی دارد.

بنابراین رابطه کلی را می‌توان به شکل زیر بیان کرد:

۳. پیش‌بینی بار الکتریکی

پیش‌بینی بار به فرآیند تخمین تقاضای الکتریکی در آینده گفته می‌شود. این پیش‌بینی از نظر افق زمانی به سه گروه اصلی تقسیم می‌شود.

۳.۱. Short-Term Load Forecasting

پیش‌بینی کوتاه‌مدت معمولاً بازه چند دقیقه تا چند روز آینده را دربر می‌گیرد.

این نوع پیش‌بینی در موارد زیر کاربرد دارد:

- Unit Commitment
- Economic Dispatch
- مدیریت ذخیره
- Demand Response
- مدیریت باتری
- بازار برق

۳.۲. Medium-Term Load Forecasting

این نوع پیش‌بینی از چند روز تا چند ماه را پوشش می‌دهد و در برنامه‌ریزی خرید انرژی، تعمیرات و مدیریت منابع کاربرد دارد.

۳.۳. Long-Term Load Forecasting

پیش‌بینی بلندمدت برای افق چند ساله انجام می‌شود و در برنامه‌ریزی توسعه نیروگاه‌ها، خطوط انتقال و شبکه توزیع کاربرد دارد.

یکی از نکات مهم این است که مدل مناسب برای هر افق زمانی الزاماً یکسان نیست. برای مثال، وابستگی‌های زمانی کوتاه‌مدت ممکن است در پیش‌بینی فردا اهمیت بیشتری داشته باشند، درحالی‌که عوامل اقتصادی و رشد جمعیت در پیش‌بینی بلندمدت اهمیت بیشتری پیدا می‌کنند.

۴. داده‌های مورد استفاده در Machine Learning

موفقیت مدل‌های Machine Learning تا حد زیادی به کیفیت داده وابسته است. مهم‌ترین داده‌های مورد استفاده در پیش‌بینی بار عبارت‌اند از:

داده‌های تاریخی بار

مانند:

- توان اکتیو
- توان راکتیو
- انرژی مصرفی
- بار ساعتی
- بار روزانه
- پیک مصرف

داده‌های آب‌وهوایی

از جمله:

- دما
- رطوبت
- سرعت باد
- تابش خورشیدی
- فشار هوا

داده‌های زمانی

مانند:

- ساعت شبانه‌روز
- روز هفته
- ماه
- فصل
- تعطیلات

داده‌های اقتصادی و رفتاری

در مدل‌های پیشرفته‌تر می‌توان متغیرهایی مانند قیمت برق، نوع مصرف‌کننده، حضور افراد در ساختمان و میزان استفاده از تجهیزات برقی را نیز در نظر گرفت.

برای نمونه، بردار ورودی مدل می‌تواند به شکل زیر تعریف شود:

$$X_t = [L_{t-1}, L_{t-24}, L_{t-168}, T_t, H_t, D_t]$$

که در آن:

- L_{t-1} : بار ساعت قبل
- L_{t-24} : بار ۲۴ ساعت قبل
- L_{t-168} : بار یک هفته قبل
- T_t : دمای فعلی
- H_t : رطوبت
- D_t : ویژگی‌های تقویمی

است.

۵. آماده‌سازی داده‌ها

داده‌های خام شبکه معمولاً مستقیماً برای آموزش مدل مناسب نیستند. بنابراین، مرحله **Data Preprocessing** اهمیت زیادی دارد.

۵.۱. مدیریت داده‌های مفقود

ممکن است به علت خطای ارتباطی یا خرابی تجهیزات، بخشی از داده‌های کنترل ثبت نشده باشد. روش‌هایی مانند Interpolation یا استفاده از داده‌های زمانی مشابه می‌توانند برای تکمیل داده‌ها استفاده شوند.

۵.۲. حذف یا اصلاح داده‌های غیرواقعی

برای مثال، اگر کنترل مقدار بسیار بزرگی را ثبت کند، باید مشخص شود که آیا این مقدار یک پیک واقعی است یا ناشی از خطای اندازه‌گیری.

۵.۳. Normalization

ویژگی‌های ورودی ممکن است مقیاس‌های بسیار متفاوتی داشته باشند. به همین دلیل، در برخی مدل‌ها از روش‌هایی مانند Min-Max Scaling یا Standardization استفاده می‌شود.

۵.۴. Feature Engineering

در این مرحله ویژگی‌های جدیدی از داده‌های خام استخراج می‌شوند.

برای مثال:

$$Load_{lag24} = Load(t - 24)$$

یا:

$$Load_{lag168} = Load(t - 168)$$

می‌تواند اطلاعات ارزشمندی درباره الگوهای روزانه و هفتگی مصرف ارائه دهد.

۶. الگوریتم‌های Machine Learning برای پیش‌بینی بار

۶.۱. Linear Regression

رگرسیون خطی یکی از ساده‌ترین روش‌های پیش‌بینی است:

$$\hat{y} = \beta_0 + \sum_{i=1}^n \beta_i X_i$$

مزیت اصلی این روش سادگی و تفسیرپذیری آن است. با این حال، رابطه میان بار و متغیرهایی مانند دما معمولاً کاملاً خطی نیست؛ بنابراین ممکن است رگرسیون ساده در شرایط پیچیده دقت کافی نداشته باشد.

۶.۲. Support Vector Regression

Support Vector Regression (SVR) نسخه‌ای از Support Vector Machine برای مسائل رگرسیونی است.

SVR با استفاده از Kernel Function می‌تواند روابط غیرخطی را مدل کند. این روش در مجموعه داده‌های با اندازه متوسط می‌تواند عملکرد مناسبی داشته باشد.

با این حال، انتخاب پارامترهای Kernel و هزینه محاسباتی در مجموعه داده‌های بسیار بزرگ از محدودیت‌های آن محسوب می‌شود.

۶.۳. Random Forest

Random Forest از تعداد زیادی Decision Tree تشکیل می‌شود.

هر درخت بخشی از داده‌ها و ویژگی‌ها را بررسی می‌کند و نتیجه نهایی از ترکیب خروجی درخت‌ها حاصل می‌شود.

مزایای Random Forest شامل:

- توانایی مدل‌سازی روابط غیرخطی
- مقاومت نسبی در برابر نویز
- امکان بررسی اهمیت ویژگی‌ها
- نیاز کمتر به تنظیمات پیچیده نسبت به برخی مدل‌های Deep Learning

است.

۶.۴. Gradient Boosting

در روش‌های Gradient Boosting، مدل‌ها به صورت متوالی آموزش داده می‌شوند و هر مرحله تلاش می‌کند خطاهای مراحل قبلی را کاهش دهد.

الگوریتم‌هایی مانند XGBoost و LightGBM در بسیاری از مسائل داده‌محور عملکرد مناسبی دارند.

در پروژه‌های پیش‌بینی بار، این مدل‌ها به خصوص زمانی مفید هستند که داده شامل مجموعه‌ای از ویژگی‌های مهندسی شده مانند دما، ساعت، روز هفته و Lag Features باشد.

۷ Deep Learning. در پیش‌بینی بار

با افزایش حجم داده‌های Smart Meter، استفاده از Deep Learning اهمیت بیشتری پیدا کرده است.

۷.۱ Artificial Neural Network.

شبکه عصبی مصنوعی یا ANN از نورون‌های مصنوعی تشکیل می‌شود و می‌تواند روابط غیرخطی میان ورودی‌ها و خروجی را یاد بگیرد.

ساختار کلی آن شامل:

Input Layer → Hidden Layers → Output Layer

است.

در مسئله پیش‌بینی بار، ورودی می‌تواند شامل داده‌های تاریخی بار و شرایط آب‌وهوایی باشد و خروجی، بار پیش‌بینی شده برای یک یا چند ساعت آینده باشد.

۸ LSTM. و پیش‌بینی سری زمانی

یکی از مهم‌ترین معماری‌های Deep Learning برای پیش‌بینی بار، Long Short-Term Memory (LSTM) است.

بار الکتریکی یک سری زمانی است؛ بنابراین مقدار فعلی آن به مقادیر گذشته وابستگی دارد. LSTM با استفاده از ساختار حافظه‌ای خود می‌تواند وابستگی‌های زمانی را بهتر از یک شبکه عصبی ساده مدل کند.

برای نمونه، در پیش‌بینی بار ساعت ۱۸، ممکن است موارد زیر اهمیت داشته باشند:

- بار ساعت ۱۷
- بار ساعت ۱۶
- بار ساعت ۱۸ روز قبل
- بار ساعت ۱۸ هفته قبل
- دمای فعلی
- دمای چند ساعت گذشته
- وضعیت روز هفته

LSTM می‌تواند بخشی از این وابستگی‌های زمانی را از طریق توالی داده‌ها یاد بگیرد.

۹. Transformer. در پیش‌بینی بار

یکی از تحولات جدید در حوزه پیش‌بینی سری‌های زمانی، استفاده از معماری **Transformer** است.

Transformer بر پایه مکانیزم **Attention** عمل می‌کند. این مکانیزم به مدل اجازه می‌دهد مشخص کند کدام بخش‌های توالی ورودی برای پیش‌بینی خروجی اهمیت بیشتری دارند.

این ویژگی در سری‌های زمانی طولانی اهمیت دارد؛ زیرا ممکن است برخی نقاط زمانی گذشته ارتباط بیشتری با وضعیت آینده داشته باشند.

با این حال، پیچیده‌تر بودن مدل الزاماً به معنای بهتر بودن آن نیست. مدل‌های Transformer معمولاً به داده، محاسبات و تنظیم دقیق بیشتری نیاز دارند و باید در برابر مدل‌های ساده‌تر روی داده واقعی ارزیابی شوند.

۱۰. معیارهای ارزیابی مدل

برای مقایسه مدل‌های مختلف باید از معیارهای کمی استفاده کرد.

Mean Absolute Error

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

هرچه MAE کمتر باشد، خطای مطلق متوسط مدل کمتر است.

Root Mean Square Error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

RMSE نسبت به خطاهای بزرگ حساس‌تر است.

Mean Absolute Percentage Error

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

MAPE خطا را به صورت درصد بیان می‌کند؛ باین حال، زمانی که مقدار واقعی بار بسیار کوچک یا نزدیک صفر باشد، می‌تواند معیار نامناسبی باشد.

بنابراین ارزیابی مناسب بهتر است از چند معیار به صورت هم‌زمان استفاده کند.

۱۱. ارتباط Machine Learning با مدیریت انرژی

هدف نهایی پیش‌بینی بار، صرفاً تولید یک عدد برای ساعت آینده نیست.

فرض کنید سیستم پیش‌بینی کند:

$$\hat{L}_{19:00} = 850 MW$$

این اطلاعات می‌تواند به سیستم مدیریت انرژی داده شود تا درباره نحوه تأمین این بار تصمیم بگیرد.

برای مثال:

- نیروگاه‌های مناسب را وارد مدار کند .
- ذخیره انرژی را فعال کند .
- شارژ خودروهای برقی را جابه‌جا کند .
- باتری را دشارژ کند .
- بارهای انعطاف‌پذیر را کاهش دهد .
- انرژی بیشتری از منابع تجدیدپذیر استفاده کند .

در نتیجه، ساختار کامل به شکل زیر خواهد بود:

Load Data → Machine Learning → Load Forecast → Optimization → Energy Management

این نکته اهمیت بنیادی دارد **Machine Learning**: پیش‌بینی را انجام می‌دهد، درحالی‌که الگوریتم بهینه‌سازی از پیش‌بینی برای تصمیم‌گیری استفاده می‌کند.

۱۲. Demand Response

Demand Response (DR) یکی از کاربردهای مهم پیش‌بینی بار در شبکه هوشمند است.

در Demand Response، مصرف‌کنندگان می‌توانند مصرف برق خود را بر اساس شرایط شبکه یا قیمت برق تغییر دهند.

برای مثال، اگر مدل Machine Learning پیش‌بینی کند که در ساعت ۱۹ تقاضای بسیار زیادی وجود خواهد داشت، EMS می‌تواند:

۱. باتری را در ساعت ۱۹ دشارژ کند.
۲. شارژ خودروهای برقی را به ساعت دیگری منتقل کند.
۳. بارهای غیرضروری را کاهش دهد.
۴. از منابع تولید پراکنده استفاده کند.
۵. مصرف‌کنندگان را به کاهش مصرف تشویق کند.

IEA در گزارش‌های مربوط به انعطاف‌پذیری تقاضا بر نقش Demand Response در مدیریت پیک و ادغام منابع تجدیدپذیر تأکید کرده است. (IEA, ۲۰۲۶)

۱۳. مدیریت باتری و ذخیره‌سازی انرژی

باتری یکی از عناصر مهم شبکه‌های هوشمند و Microgrid هاست.

فرض کنید باتری در ساعت کم‌تقاضا شارژ شود و در زمان پیک دشارژ گردد.

اگر بار آینده به‌درستی پیش‌بینی شود، EMS می‌تواند زمان بهینه شارژ و دشارژ را تعیین کند.

یک تابع هدف ساده برای این مسئله می‌تواند به صورت زیر باشد:

$$\min \sum T C_t P_t^{grid}$$

که در آن C_t قیمت برق و P_t^{grid} میزان توان خریداری‌شده از شبکه است.

در مدل‌های پیشرفته‌تر می‌توان هزینه استهلاک باتری، محدودیت State of Charge و محدودیت توان شارژ و دشارژ را نیز وارد کرد.

۱۴. مدیریت انرژی تجدیدپذیر

یکی از مهم‌ترین کاربردهای Machine Learning در شبکه آینده، هماهنگ‌سازی بار با تولید تجدیدپذیر است.

تولید خورشیدی تابع تابش خورشید و شرایط آب‌وهوایی است و تولید باد نیز به سرعت و جهت باد وابستگی دارد.

در این شرایط می‌توان مقدار **Net Load** را تعریف کرد:

$$Net Load = Load - Renewable Generation$$

اگر تولید خورشیدی افزایش یابد، **Net Load** کاهش پیدا می‌کند.

EMS می‌تواند در این شرایط انرژی اضافی را برای:

- شارژ باتری
- شارژ خودروهای برقی
- بارهای انعطاف‌پذیر

استفاده کند.

بنابراین یک سیستم هوشمند بهتر است به‌صورت هم‌زمان سه مسئله را در نظر بگیرد:

Load Forecasting + Renewable Forecasting + Energy Optimization

۱۵. چالش‌های استفاده از Machine Learning

۱۵.۱. کیفیت داده

مدل پیشرفته با داده ضعیف الزاماً نتیجه خوبی ارائه نمی‌دهد **Missing Data**، **Noise** و خطاهای اندازه‌گیری می‌توانند دقت پیش‌بینی را کاهش دهند.

۱۵.۲. تغییر الگوی مصرف

رفتار مصرف‌کننده ثابت نیست. تغییر قیمت برق، استفاده از خودروهای برقی، تغییرات اقتصادی و حتی تغییر عادات کاری می‌تواند باعث ایجاد **Concept Drift** شود.

۱۵.۳. پیش‌بینی پیک

پیش‌بینی میانگین بار با پیش‌بینی دقیق پیک یکسان نیست. از نظر بهره‌برداری سیستم قدرت، یک خطای کوچک در زمان پیک ممکن است اهمیت بیشتری از خطای مشابه در ساعات کم‌بار داشته باشد.

۱۵.۴. Explainability

مدل‌های پیچیده مانند LSTM و Transformer ممکن است پیش‌بینی دقیقی ارائه دهند، اما در بسیاری از موارد توضیح چرایی پیش‌بینی دشوار است.

استفاده از Explainable AI (XAI) می‌تواند به شناسایی عوامل مؤثر بر پیش‌بینی کمک کند.

۱۵.۵. امنیت سایبری

شبکه هوشمند به زیرساخت ارتباطی وابسته است. بنابراین حملات سایبری می‌توانند داده‌های مورد استفاده مدل را تغییر داده یا عملکرد سامانه مدیریت انرژی را مختل کنند.

۱۶. معماری پیشنهادی برای یک پروژه مهندسی برق

برای یک پروژه دانشگاهی می‌توان سیستم زیر را طراحی کرد:

مرحله اول: جمع‌آوری داده

داده‌های بار ساعتی به همراه اطلاعات آب‌وهوایی جمع‌آوری شوند.

مرحله دوم: Preprocessing :

داده‌های ناقص و غیرواقعی شناسایی و داده‌ها Normalize شوند.

مرحله سوم: Feature Engineering :

ویژگی‌هایی مانند Lag_1 ، Lag_{24} و Lag_{168} ایجاد شوند.

مرحله چهارم: آموزش مدل‌ها

چند مدل با یک مجموعه داده یکسان آموزش داده شوند:

- Linear Regression
- Random Forest
- XGBoost
- SVR
- ANN
- LSTM

مرحله پنجم: ارزیابی

مدل‌ها با MAE ، $RMSE$ و $MAPE$ مقایسه شوند.

مرحله ششم: مدیریت انرژی

خروجی بهترین مدل به یک الگوریتم Optimization داده شود.

مرحله هفتم: کنترل

بر اساس نتیجه Optimization، عملکرد باتری، بارهای قابل کنترل و منابع تولید تنظیم شود.

این ساختار می‌تواند مبنای یک پروژه کارشناسی، کارشناسی ارشد یا مقاله پژوهشی در حوزه مهندسی برق – قدرت قرار گیرد.

۱۷. آینده Machine Learning در شبکه‌های هوشمند

تحقیقات آینده احتمالاً به سمت مدل‌هایی حرکت خواهند کرد که علاوه بر دقت بالا، قابلیت سازگاری با شرایط متغیر شبکه را نیز داشته باشند.

یکی از حوزه‌های مهم، **Federated Learning** است. در این روش، امکان آموزش مدل با حفظ بیشتر حریم خصوصی داده‌های مصرف‌کنندگان فراهم می‌شود.

حوزه دیگر **Graph Neural Networks (GNN)** است. از آنجا که شبکه برق دارای توپولوژی مشخصی از باس‌ها و خطوط انتقال و توزیع است، GNN می‌تواند روابط مکانی میان اجزای شبکه را در مدل‌سازی وارد کند.

همچنین **Probabilistic Forecasting** اهمیت زیادی دارد. به جای پیش‌بینی یک مقدار قطعی، مدل می‌تواند بازه یا توزیع احتمالی بار آینده را ارائه کند.

برای مثال، به جای:

$$Load = ۸۰۰ MW$$

می‌توان نتیجه گرفت:

$$P(750 < Load < 850) = 0.90$$

چنین اطلاعاتی برای تصمیم‌گیری تحت عدم قطعیت ارزشمند است.

۱۸. نتیجه‌گیری

شبکه هوشمند حاصل ترکیب سیستم قدرت با فناوری‌های اندازه‌گیری، ارتباطات و پردازش داده است. افزایش منابع تجدیدپذیر، خودروهای برقی، ذخیره‌سازها و تولید پراکنده باعث شده است بهره‌برداری از شبکه به اطلاعات دقیق‌تر و پیش‌بینی‌های قابل‌اعتمادتر نیاز داشته باشد.

در این میان، **Machine Learning** ابزار مهمی برای پیش‌بینی بار الکتریکی محسوب می‌شود. الگوریتم‌هایی مانند Random Forest، SVR و Gradient Boosting برای داده‌های ساختاریافته و مدل‌هایی مانند ANN، LSTM و Transformer برای الگوهای پیچیده و سری‌های زمانی قابل استفاده هستند.

با این حال، انتخاب مدل نباید تنها بر اساس پیچیدگی یا جدید بودن الگوریتم صورت گیرد. کیفیت داده، افق پیش‌بینی، ویژگی‌های شبکه، هزینه محاسبات، قابلیت تفسیر و هدف نهایی سیستم همگی باید در انتخاب مدل در نظر گرفته شوند.

مهم‌ترین نتیجه آن است که **پیش‌بینی بار به‌تنهایی هدف نهایی نیست**. ارزش واقعی Machine Learning زمانی آشکار می‌شود که پیش‌بینی حاصل مستقیماً در سیستم مدیریت انرژی، Demand Response، کنترل ذخیره‌سازها، مدیریت خودروهای برقی و ادغام منابع تجدیدپذیر مورد استفاده قرار گیرد.

بنابراین، معماری مطلوب شبکه‌های هوشمند آینده را می‌توان به صورت زیر خلاصه کرد:

*Data → Machine Learning → Forecasting → Optimization → Energy Management
→ Control*

این رویکرد می‌تواند زمینه‌ساز ایجاد سیستم‌های قدرتی شود که نه تنها وضعیت فعلی شبکه را پایش می‌کنند، بلکه با پیش‌بینی شرایط آینده، تصمیم‌های بهره‌برداری اقتصادی، پایدار و هوشمندانه اتخاذ می‌کنند.

١. International Energy Agency. (٢٠٢٦). *Electricity 2026: Analysis and forecast to 2030*. IEA.
٢. International Energy Agency. (٢٠٢٦). *Scaling Up Demand Flexibility: From Peak Management to Efficient System Operation*. IEA.
٣. Sardi, A., et al. (٢٠١٧). Electrical load forecasting models: A critical systematic review. *Sustainable Cities and Society*, 35, ٢٥٧–٢٧٠.
٤. Hou, H., Liu, C., Wang, Q., Wu, X., Tang, J., Shi, Y., & Xie, C. (٢٠٢٢). Review of load forecasting based on artificial intelligence methodologies, models, and challenges. *Electric Power Systems Research*, 210, ١٠٨٠٦٧.
٥. *Short-Term Electricity-Load Forecasting by Deep Learning: A Comprehensive Survey*. (٢٠٢٥). *Engineering Applications of Artificial Intelligence*, 154, ١١٠٩٨٠.
٦. *Explainability and Interpretability in Electric Load Forecasting Using Machine Learning Techniques – A Review*. (٢٠٢٤). *Energy and AI*, 16, ١٠٠٣٥٨.
٧. *Machine Learning in Peak Demand Forecasting: Foundations, Trends, and Insights*. (٢٠٢٦). *Renewable and Sustainable Energy Reviews*.
٨. *Short-Term Electricity Load Forecasting: Application-Driven Evaluation of Machine Learning Models Across Spatial and Temporal Scales*. (٢٠٢٦). *Engineering Applications of Artificial Intelligence*.
٩. *Bridging Prediction and Decision: An Application-Driven Review of Load Forecasting in Energy Systems*. (٢٠٢٦). *Computers and Electrical Engineering*.