

Intelligenza Artificiale per la transizione ecologica: la manutenzione predittiva nei parchi fotovoltaici

Il caso di successo con SAIDEA ed Eurac Research

Contenuti

3	L'azienda cliente: SAIDEA
4	La sfida
5	La soluzione
7	Fase 1. L'analisi del dataset
8	Fase 2. L'annotazione del dataset
9	Fase 3. Lo sviluppo del modello di IA e il suo training
11	Conclusione

Sum-up

Cliente: SAIDEA Srl

Ambito di applicazione: energie rinnovabili, manutenzione predittiva

Expertise: Intelligenza Artificiale / Machine Learning

L'azienda cliente: SAIDEA

L'azienda cliente di questo *case study* è [SAIDEA Srl](#), società di servizi ICT che si occupa di sviluppo software e gestione in outsourcing di sistemi informativi aziendali. SAIDEA è Partner del progetto “*EU FESR1128 PV4.0 - Utilizzo di logiche Industry 4.0 e Internet of Things nel settore fotovoltaico*”, coordinato dall'[Istituto per le Energie Rinnovabili](#) di [Eurac Research](#), con l'obiettivo di ottimizzare

gli interventi di manutenzione su impianti e parchi fotovoltaici. Nell'ambito di questa collaborazione è nata l'esigenza di avvalersi di un fornitore esterno per lo sviluppo e l'integrazione di modelli di manutenzione predittiva basati sull'Intelligenza Artificiale; e **U-Hopper Srl è stato scelto sulla base della sua riconosciuta eccellenza nel campo dei modelli predittivi per l'analisi dei dati.**



La sfida



Il settore del **fotovoltaico** è uno dei **protagonisti principali del percorso di transizione ecologica** in atto a livello nazionale, europeo e globale. Uno degli aspetti che ha spinto l'adozione del fotovoltaico su larga scala è indubbiamente il **calo dei costi legati agli investimenti iniziali necessari** (costi di moduli ed inverter, soprattutto).

Al tempo stesso, **la maggiore competizione nel settore, ha portato ad un calo della marginalità per gli operatori attivi nel settore del monitoraggio e manutenzione** degli impianti (O&M). Per gli operatori O&M, la manutenzione di un parco fotovoltaico **comporta costi e tempi** che dipendono dal numero di guasti o malfunzionamenti e che si sommano alle normali operazioni di routine.

Essere in grado di **prevenire tali guasti e malfunzionamenti**, come per esempio un calo indesiderato dell'energia prodotta per un tempo prolungato, **permette di intervenire tempestivamente**. Di conseguenza, è possibile **ridurre i tempi di fermo tecnico e minimizzare i costi (perdite di guadagno)** ad essi associati.

Questo *modus operandi* prende il nome di **manutenzione predittiva**, oggi un pilastro fondamentale dell'Industria 4.0, la quale si avvale di tecnologie IoT per il monitoraggio dei dispositivi tramite sensori e di algoritmi di Intelligenza Artificiale per l'elaborazione dei dati da essi generati. Si stima che il **mercato globale** della manutenzione predittiva possa valere almeno **12,3 miliardi di dollari nel 2025** (fonte: [Capgemini](#)).

Considerando la pressione competitiva nel settore O&M, l'avere a disposizione strumenti e servizi per la manutenzione predittiva può fare la differenza tra il crescere sul mercato e il lottare per la sopravvivenza. Consapevole dei vantaggi che si possono ottenere grazie alla manutenzione predittiva, SAIDEA ha affidato al nostro team la realizzazione

di una serie di metodi e modelli, basati sull'Intelligenza Artificiale, **in grado di predire autonomamente l'occorrenza di anomalie e di malfunzionamenti agli impianti fotovoltaici** e poterli comunicare tempestivamente al team di manutenzione per evitare guasti e rotture.

“Per completare quello che va a rappresentare il Decision Support System in Antares, la nostra piattaforma di Enterprise Service Management (EMS), risultava di centrale importanza la realizzazione di un algoritmo per l'attività preventiva di analisi dell'impianto. Partendo da precise specifiche, il lavoro di U-Hopper ha permesso la realizzazione di un modello efficace per la manutenzione simil-predittiva, da integrarsi in Antares per rendere ancora più completo il sistema di gestione sviluppato.”

Filippo Segata

Project Manager

La soluzione

La soluzione proposta dal nostro team a questa sfida consiste quindi in una **piattaforma**, integrabile con il sistema di Enterprise Service Management [Antares](#) di Saidea, **in grado di raccogliere ed analizzare i dati generati dai sensori** dei parchi fotovoltaici con l'obiettivo di monitorare il loro funzionamento e notificare eventuali malfunzionamenti.

L'**algoritmo al cuore** della piattaforma si basa su un **robusto modello di Machine Learning**, il cui training è stato completato grazie ad un ricco dataset fornitoci da Eurac Research contenente più di quattro anni di dati storici da noi annotati, dal 2014 al 2018, per un totale di 2,5 milioni di misurazioni rilevate ad intervalli di 10 minuti.

Il processo di sviluppo della soluzione per SAIDEA si è suddiviso in **cinque fasi**:



1. Analisi del dataset

attraverso l'uso di analisi statistiche e di rappresentazioni grafiche dei dati, sono state identificate alcune decine di esempi di comportamenti anomali e normali ed individuate le informazioni più rilevanti e funzionali all'algoritmo di ML per la loro distinzione;



2. Annotazione del dataset

premesso che i dati contenuti nel dataset iniziale non erano associati a delle *etichette* che distinguessero il caso di “malfunzionamento” dalla casistica “comportamento nella norma”, durante la seconda fase è stata svolta un'annotazione manuale del dataset, identificando le *regole* per classificare i due casi sulla base di analisi statistiche;



3. Sviluppo del modello di IA e il suo training

è stato creato un modello di Machine Learning (ML) ed è stato calibrato al fine di rilevare autonomamente le possibili anomalie in futuro, secondo le regole definite alla Fase 2;



4. Ingegnerizzazione software

in questa fase i metodi e modelli creati nella Fase 3 sono stati ingegnerizzati e sono stati aggiunti i componenti necessari per facilitarne l'integrazione lato tecnico (APIs);



5. Integrazione e messa in opera

il prototipo ingegnerizzato è stato integrato con la piattaforma di SAIDEA, con il software per l'acquisizione dei dati dagli impianti e messo in opera in cloud.

Ci focalizzeremo ora sulle prime tre fasi, dove la **componente di data science è preponderante**.

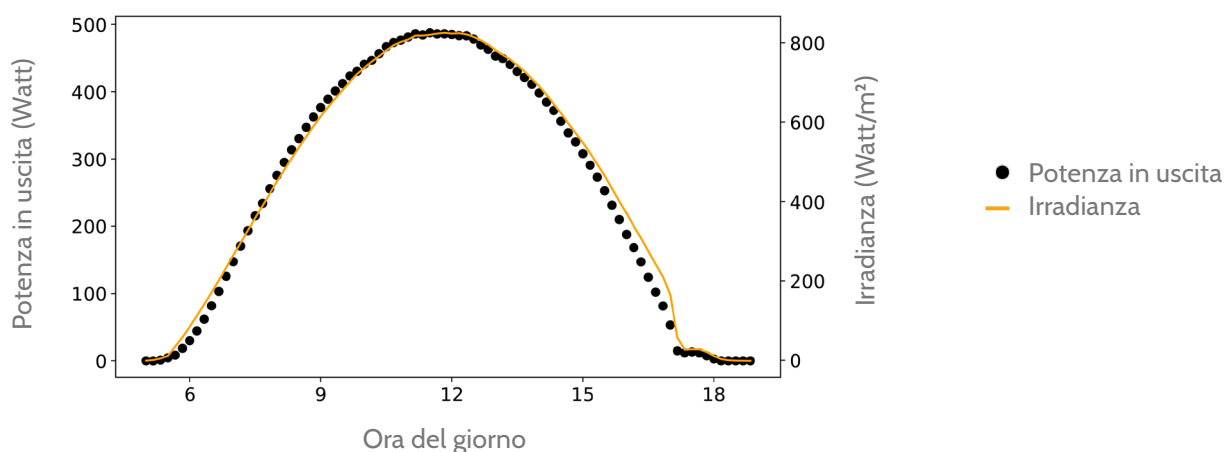
Fase 1. L'analisi del dataset

Il dataset a nostra disposizione era costituito da un **numero elevato di dati riferiti allo stato di salute di diversi *inverter***, ovvero dispositivi installati sui pannelli fotovoltaici che convertono l'energia solare, generata sotto forma di corrente continua, in corrente alternata.

Essendo però il **dataset non annotato²**, l'analisi iniziale si è basata sull'osservazione di grafici come quello riportato qui sotto che rappresenta una giornata soleggiata

senza nuvole. In linea teorica, maggiore è l'irraggiamento che i pannelli solari ricevono dal Sole, maggiore dovrebbe essere l'energia da essi prodotta.

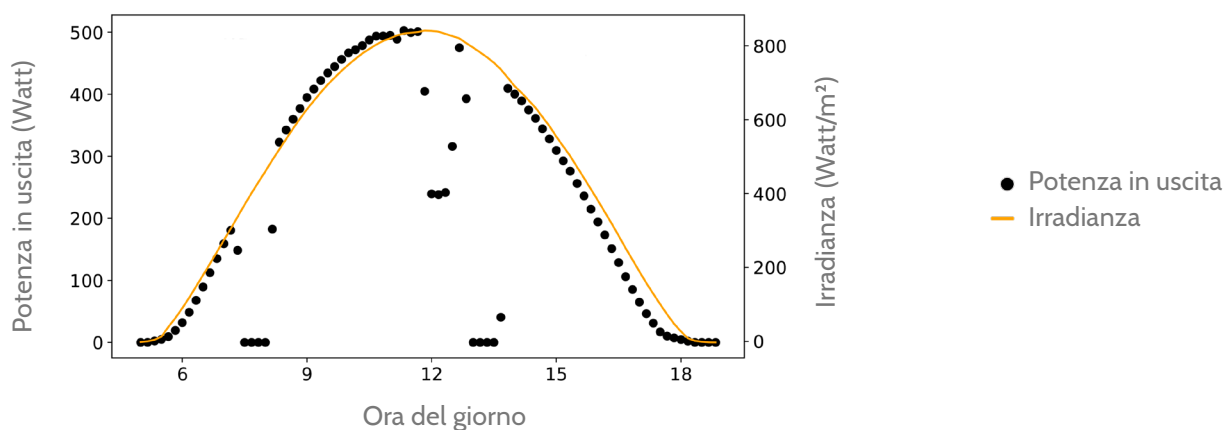
In questo caso, si può notare come la corrente prodotta dall'*inverter* (rappresentata dai puntini neri) segua fedelmente la curva arancione (che indica invece l'irradianza, ossia l'energia che i pannelli solari hanno ricevuto dal Sole), indicando quindi un funzionamento corretto dell'impianto.



² cioè i dati in esso contenuti non forniscono informazioni sul loro significato - in questo caso, non era indicato se un dato si riferisse ad un caso di malfunzionamento o meno. Per saperne di più, leggi [questo articolo](#) sul nostro blog.

Nel grafico qui sotto invece, altro esempio di una giornata soleggiata senza nuvole, si possono invece osservare diversi malfunzionamenti, evidenziati dalle


misurazioni della potenza generata dagli inverter (puntini neri) che si discostano significativamente rispetto dalla curva dell'irradianza.



Fase 2. L'annotazione del dataset

Tenuto conto delle analisi e considerazioni raccolte nella Fase 1, si è provveduto alla creazione di una serie di **euristiche** che, combinate tra loro, **fossero in grado di annotare lo stato di funzionamento di ciascun inverter all'interno del dataset**. Il risultato di questa operazione può essere

osservato nella figura sottostante. In questo modo è stato possibile ottenere un dataset annotato e creare un modello di Machine Learning (nello specifico, di *supervised learning*) in grado di classificare autonomamente lo stato di funzionamento di ciascun inverter.



Perché allenare un modello di Machine Learning a riconoscere lo stato di funzionamento di un inverter quando siamo stati in grado di farlo manualmente con la creazione di una serie di regole ad hoc?

La creazione delle **euristiche** è frutto di un'analisi "combinata" che **mette a confronto i dati generati da un inverter con i dati generati da altri inverter**, allo scopo di individuare eventuali comportamenti anomali. Inoltre, **si basa su una serie storica** di osservazioni che permette, ad esempio, di rilevare fasi di stallo - ossia lassi temporali prolungati in cui un inverter genera una potenza in uscita costante inferiore al suo massimo.

Il modello di Machine Learning, invece, è pensato per **analizzare flussi continui di dati e relativi allo stato del singolo inverter**; pertanto, una volta appreso dalle euristiche come classificare determinate situazioni, il modello è in grado di poter operare in **real-time** e in **autonomia sul singolo inverter**, senza richiedere il confronto con gli altri o attendere del tempo per far sì che la fase di stallo si manifesti esplicitamente, in quanto il modello è capace di rilevare ed interpretare nel modo corretto sin da subito le prime avvisaglie di comportamenti anomali.

Da un lato, ciò garantisce al modello di Machine Learning **maggiore flessibilità di impiego**, dato che può essere utilizzato anche in impianti con un solo inverter (nei quali, dunque, sia impossibile il confronto tra l'output di inverter diversi). Dall'altro **permette interventi di manutenzione più tempestivi**, visto che non occorre effettuare più misurazioni consecutive per stabilire se una data rilevazione sia anomala o meno.

Fase 3. Lo sviluppo del modello di IA e il suo training

Un modello di Machine Learning può essere considerato come uno strumento che, ricevuto un *input*, restituisce un *output* con caratteristiche prefissate. Nel caso in questione, l'*input* atteso dal modello è **dato dai valori delle variabili atmosferiche e di quelle elettriche** di un inverter in un dato istante, mentre l'*output* è **rappresentato**

dalla probabilità che l'inverter non stia funzionando correttamente in quell'istante: se questa probabilità supera una certa soglia, il comportamento dell'inverter viene classificato come anomalo (e quindi l'inverter richiederà un intervento di controllo/manutenzione).

La struttura interna del modello di ML - l'insieme cioè dei suoi parametri e delle operazioni cui viene sottoposto l'*input* dipende dalla tipologia di algoritmo che viene implementato. Per SAIDEA la scelta è caduta sulle cosiddette **Reti Neurali**, che sono attualmente considerate lo stato dell'arte nel settore nell'ambito del ML.

Affinché questa probabilità sia di volta in volta calcolata in maniera accurata, si è reso necessario **calibrare opportunamente i parametri** della Rete Neurale. È proprio **questo lo scopo del training del modello**: durante questa fase ogni record del dataset annotato viene processato per ottenere la corrispondente probabilità che si tratti di un'anomalia.

Per far questo, innanzitutto le etichette del dataset annotato (comportamento normale/anomalo) **sono state convertite in formato numerico, in probabilità, affinché potessero essere processate dalla Rete Neurale**: a quegli istanti in cui il comportamento dell'inverter era stato etichettato come *normale*, è stata assegnata una probabilità 0, mentre a quelli corrispondenti ad un comportamento anomalo una probabilità 1.

Queste probabilità rappresentano la *ground truth*, cioè la probabilità corretta di malfunzionamento corrispondente ai singoli istanti di ogni *inverter*.

Successivamente, in input alla Rete Neurale sono stati forniti i record privati della *ground truth*, contenenti quindi le sole variabili atmosferiche ed elettriche. La *ground truth* viene invece confrontata con la probabilità in uscita dal modello: in base alla correttezza o meno del risultato predetto da quest'ultimo, **i parametri della Rete Neurale vengono aggiornati in modo "intelligente"** al fine di riuscire a replicare il più fedelmente possibile le probabilità ottenute grazie alle euristiche.

Questa procedura viene ripetuta per tutti i record del dataset annotato per alcune decine/centinaia di volte, fino a che - complessivamente - **le predizioni si stabilizzano**: la configurazione dei parametri che alla fine ne risulta corrisponderà, di fatto, al modello che verrà messo a disposizione del cliente e che procederà alla classificazione delle istanze che verranno registrate in futuro.

Il risultato finale è un **modello allenato**, ovvero uno strumento che, sulla base dell'esperienza acquisita nel processo di training, è **in grado di riconoscere con alto grado di affidabilità la presenza di malfunzionamenti nel sistema**. Questo modello allenato è quello che poi è stato integrato nella piattaforma di SAIDEA, per permettere agli operatori O&M di predisporre interventi tempestivi di manutenzione sull'impianto.

Conclusione

A partire dal 2020, in concomitanza con lo scoppio della pandemia da Covid-19, a livello globale si è sentita **la necessità di accelerare la transizione energetica già in atto**. Ciò è avvenuto in parte come conseguenza del cambiamento della linea politica di alcuni paesi, [come è accaduto negli USA](#), in parte per i vincoli imposti dalla Commissione Europea sulla [Next Generation EU](#): **almeno il 37% dei fondi destinati a ciascun paese europeo devono essere destinati alla transizione energetica e al cambiamento climatico**.

Secondo l'[Agenzia internazionale dell'energia](#), **entro il 2050 le fonti rinnovabili dovranno alimentare le economie globali per almeno il 90%**. Ma obiettivi a breve-medio termine, come quelli posti dalla [Commissione Europea](#), sono stati fissati anche per il 2030; in Italia, per esempio, dove si aspira a produrre il 32% di energia dalle fonti rinnovabili entro tale anno, si stima che sia necessario installare impianti per 70 GW.

Inoltre, l'ambizione è quella di **incrementare la loro efficienza energetica; e la manutenzione predittiva concorre al raggiungimento di tale obiettivo** in quanto permette di intervenire tempestivamente andando a sostituire quei componenti la cui efficienza energetica risulta scesa sotto una certa soglia.

Il sistema sviluppato da U-Hopper ha consentito a SAIDEA di rilevare i comportamenti anomali degli *inverter*, suggerendo quindi una manutenzione oculata prima che fosse troppo tardi. La soluzione proposta è un **strumento automatizzato a 360°**: dall'acquisizione dei dati ricevuti dai sensori dell'impianto, fino alla predizione dello stato di salute del singolo *inverter*. Tale **soluzione può facilmente essere adattata ad altri impianti fotovoltaici** aventi diverse tipologie di *inverter* e potenzialmente anche per un uso domestico, favorendo quindi la transizione energetica ad un livello più capillare.



Questa soluzione è stata realizzata nel contesto del progetto "EU FESR1128 PV 4.0 - Utilizzo di logiche Industry 4.0 e Internet of Things nel settore fotovoltaico", finanziato dal Fondo Europeo di Sviluppo Regionale (FESR) - Asse 1 "Ricerca e Innovazione".

www.u-hopper.com

info@u-hopper.com

SEDE OPERATIVA

Via R. da Sanseverino, 95

38122 Trento (TN) - Italy c/o Impact Hub

© U-Hopper Srl | Novembre 2021

U·HOPPER