CASO STUDIO · Università degli Studi di Trento, Dipartimento di Ingegneria Industriale

FEM, machine learning e know-how: quattro applicazioni alla formatura dei metalli

Panoramica

La simulazione agli elementi finiti risponde con precisione a una domanda per volta, e ogni risposta costa ore di calcolo. Il machine learning rovescia il rapporto: impara da un insieme di risposte già ottenute e ne produce di nuove in millisecondi. Il punto non è sostituire il FEM, ma usarlo per quello che sa fare meglio di qualunque campagna sperimentale, cioè generare dati affidabili e mirati.

Questo documento raccoglie quattro applicazioni sviluppate presso il Dipartimento di Ingegneria Industriale dell'Università di Trento e presentate al Simufact Day 2026. Sono quattro problemi diversi di formatura dei metalli, affrontati con quattro approcci diversi: una previsione, un'ottimizzazione, una previsione con incertezza dichiarata e un modello che funziona quando i dati sono pochissimi. Il filo che li unisce non è l'algoritmo, ma ciò che viene prima della sua scelta.

Il documento si apre con il quadro di quanta intelligenza artificiale sia realmente in uso nelle imprese manifatturiere italiane, perché è il contesto che dà la misura del problema, e si chiude con le condizioni che devono esistere in azienda perché questi metodi funzionino.

> *«Nessuna delle condizioni che servono si compra con un software: si costruiscono, si adattano, evolvono. E per farlo servono competenze e dati.»*
>
> Luca Quagliato, Ph.D. — Dipartimento di Ingegneria Industriale, Università degli Studi di Trento

Il contesto: quanta AI c'è davvero nel manifatturiero

Tre indagini recenti danno tre risposte molto diverse sulla diffusione dell'intelligenza artificiale nelle imprese europee: 19,9% secondo Eurostat, 37% secondo la Banca Europea per gli Investimenti, 71% fra le grandi imprese italiane secondo l'Osservatorio del Politecnico di Milano. I numeri non sono in contraddizione: cambiano definizione, campione e metodo di rilevazione. Eurostat è un'indagine statistica armonizzata a risposta obbligatoria su imprese con almeno dieci addetti; la BEI intervista telefonicamente il management; l'Osservatorio raccoglie dati autodichiarati e misura le PMI separatamente, dove la quota scende all'8%.

Assumendo Eurostat come base omogenea, il quadro italiano è questo: il 16,4% delle imprese con almeno dieci addetti usa almeno una tecnologia di AI, contro una media UE del 19,9%.

Il divario è di taglia, non di Paese

Classe di addetti	UE 27	Italia
10–49	17,0%	14,2%
50–249	30,4%	27,6%
250 e oltre	55,0%	53,1%

Trentanove punti fra la classe più piccola e la più grande in UE, trentotto in Italia: lo stesso divario. Non si tratta quindi di un ritardo italiano, ma di un divario dimensionale che l'Italia condivide con l'Europa, su un livello leggermente più basso in ogni classe. Nel manifatturiero la quota italiana è del 14,7%, e nei metalli e prodotti in metallo — il comparto che comprende la formatura — scende all'8,8%, contro il 14,3% europeo.

Quale AI, e che cosa la ferma

Dentro quel 16,4%, l'AI che si sta diffondendo è quella del linguaggio. Solo una impresa su cinque fra quelle che usano l'AI fa machine learning su dati: il 3,3% del totale. Un terzo di chi la usa non sa indicare in quale ambito aziendale la impieghi, quota salita dal 15,5% del 2024: segno di un'adozione rapida ma ancora sperimentale, non strutturata nei processi decisionali.

Fra le imprese che hanno valutato l'AI senza adottarla, gli ostacoli dichiarati sono, in ordine:

Ostacolo	Italia	UE 27
Mancanza di competenze	58,6%	70,3%
Poca chiarezza normativa	47,3%	53,6%
Qualità o disponibilità dei dati	45,2%	43,5%
Costi troppo elevati	43,0%	38,4%
«Non è utile per l'impresa»	14,8%	—

Il primo ostacolo non è il costo: sono le competenze e la qualità dei dati. È una distinzione che conta, perché nessuno dei due si risolve con un acquisto. Riassumendo su cento imprese italiane con almeno dieci addetti: tre fanno machine learning su dati, tredici usano l'AI per testo, voce o immagini, nove l'hanno valutata senza adottarla, settantacinque non l'hanno né usata né valutata.

Le quattro applicazioni che seguono appartengono a quel 3,3%.

Che cosa significa «machine learning su dati»

Un modello data-driven lavora su una tabella. Le colonne di ingresso sono le features, cioè i parametri che descrivono il caso: temperatura, velocità, attrito, geometria, quelli che in officina si chiamano parametri di processo. La colonna di uscita è il target, la grandezza da prevedere. Ogni riga è un campione, cioè un caso già risolto. Il machine learning cerca la funzione che lega le prime all'ultima. Regressione, albero di decisione, rete neurale: cambia il metodo, non il principio. Dentro il modello non c'è nessuna equazione fisica.

Da dove vengono i campioni

	Esempi misurati	Esempi simulati
Origine	Linea produttiva e prove sperimentali	Batch di simulazioni FEM su una griglia di parametri
Costo di un punto	Materiale e una giornata di lavoro	Tempo di calcolo
Copertura	Solo ciò che è già stato prodotto	Dove serve, deciso a tavolino
Limite	Lento da ampliare	Vale quanto vale il modello FEM che lo produce

È qui che il FEM cambia ruolo. Non è più soltanto lo strumento con cui si verifica un progetto: diventa la fabbrica che produce i campioni di addestramento, con il vantaggio di poterli collocare esattamente dove il modello ne ha bisogno.

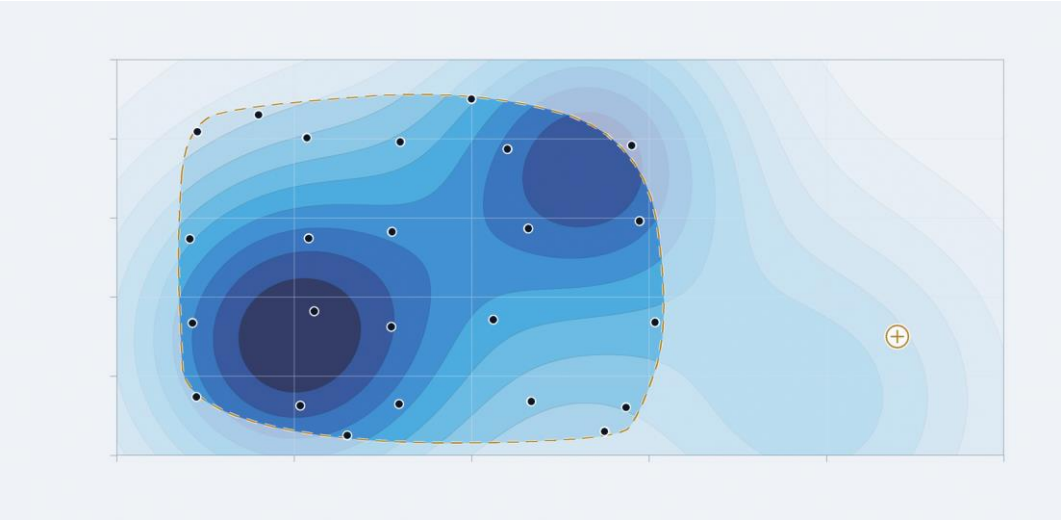


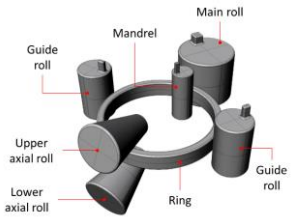
Figura 1 — Lo spazio di progetto. I punti sono le simulazioni effettivamente lanciate; il colore è la risposta del modello. Dentro il tratteggio il modello interpola fra i campioni. Fuori risponde comunque, ma senza fondamento.

Questo è il limite che accomuna tutti e quattro i casi che seguono, e va enunciato subito: un modello costruito così interpola fra i campioni che ha visto, non estrapola. Fuori dal dominio coperto dai dati continua a produrre numeri, e sta a chi lo usa sapere se quei numeri valgono. Riconoscere dove finisce il dominio è parte del metodo, non una cautela accessoria.

Caso 1 — La previsione: il FEM come fabbrica di dati

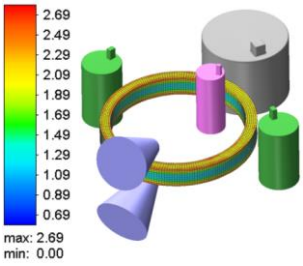
Sapere in anticipo quanta energia richiederà un ciclo di laminazione radiale-assiale di anelli, data la geometria del pezzo e i parametri di processo. La simulazione termo-meccanica la risposta ce l'ha, ma richiede ore: troppo per una preventivazione o per configurare un ciclo.

01 IL PROCESSO



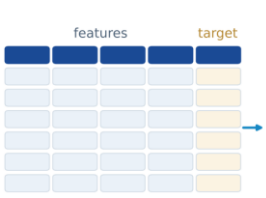
Rullo principale e mandrino riducono lo spessore, i rulli assiali l'altezza. Il diametro cresce fino alla misura voluta.

02 LE SIMULAZIONI



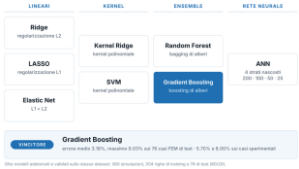
380 simulazioni in Simufact Forming 15: anelli da 650 a 2000 mm, tre materiali, tre temperature iniziali.

03 IL DATASET



Ogni simulazione diventa una riga: parametri di processo, materiale e geometria in ingresso, energia in uscita.

04 I MODELLI



Otto algoritmi addestrati sullo stesso dataset, divisi 80/20 fra training e test, per confrontarne le prestazioni.

Figura 2 — Il percorso del primo caso in quattro passaggi.

Il target è il FIOT, l'integrale della forza nel tempo di processo, buon surrogato dell'energia spesa. Nessun esperimento è stato necessario: il modello FEM era già stato validato, e l'intero dataset nasce da lì.

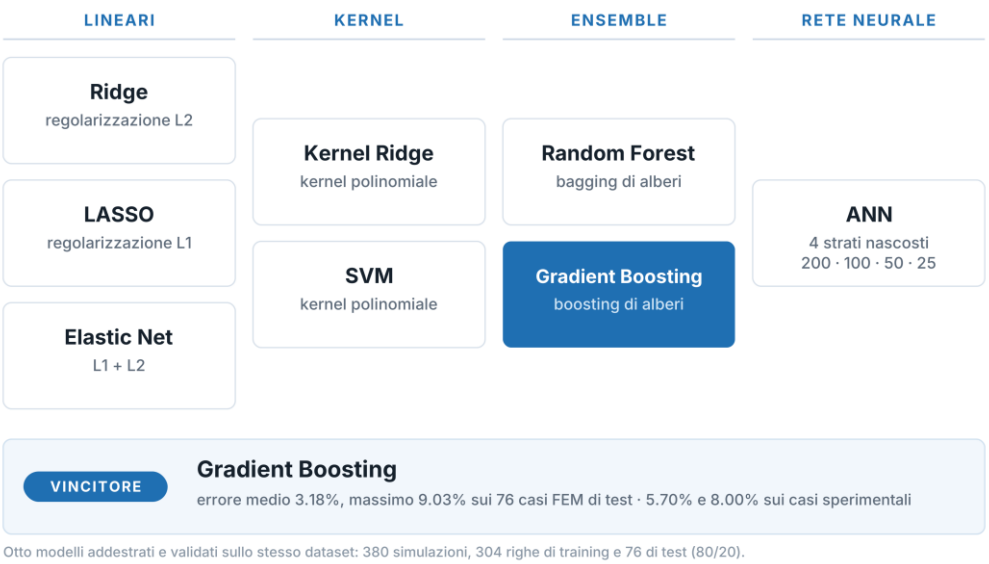


Figura 3 — Gli otto modelli a confronto sullo stesso dataset. Vince il Gradient Boosting.

I risultati

- Errore medio del 3,18% sui casi di test mai visti, massimo 9,03%
- Errore medio del 5,70% su casi sperimentali propri e di letteratura, massimo 8,00%
- La previsione è istantanea: ore di simulazione diventano millisecondi

Come si porta in azienda

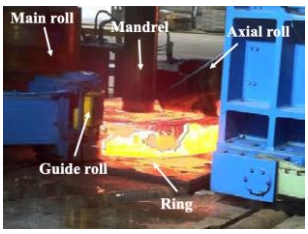
Serve una libreria di simulazioni già fatte: se esiste un archivio di analisi FEM passate, il dataset in buona parte c'è già e va solo organizzato. Lo fa chi già fa simulazione, non un data scientist: serve qualcuno che sappia quali parametri contano. Il costo sta tutto nelle 380 simulazioni e si paga una volta sola; l'addestramento dura minuti su un portatile. Il limite è che se cambia il laminatoio, o si esce dal campo di diametri simulato, il modello non se ne accorge.

> *«Funziona benissimo, e dentro al modello non c'è un grammo di fisica.»*
>
> Take-home message del primo caso

Caso 2 — L'ottimizzazione: dalla previsione alla decisione

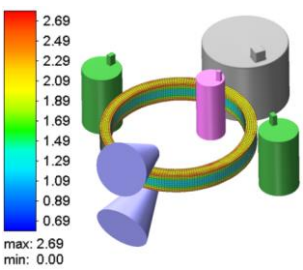
Prevedere il consumo serve a poco se non si sa quale combinazione di parametri lo minimizza. Stesso dataset, obiettivo diverso: non il consumo del ciclo che si ha in mente, ma il ciclo che consuma meno rispettando i vincoli di macchina. Le combinazioni sono troppe per provarle tutte, e la funzione da minimizzare non ha forma analitica: esiste solo come dati.

01 IL PROCESSO



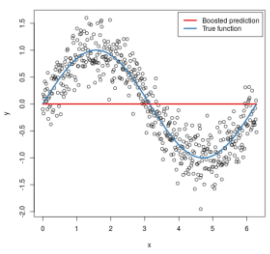
L'impianto reale: l'anello incandescente fra rullo principale, mandrino e rulli assiali.

02 IL MODELLO FEM



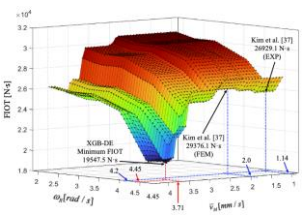
Lo stesso modello termo-meccanico validato, usato per generare i casi di addestramento.

03 PREVEDERE



L'Extreme Gradient Boosting impara la funzione obiettivo sommando centinaia di alberi.

04 OTTIMIZZARE



Una ricerca metaeuristica trova la combinazione di parametri che minimizza l'energia.

Figura 4 — Dalla funzione di previsione alla funzione obiettivo da minimizzare.

La metaeuristica è necessaria perché una funzione obiettivo fatta di alberi non è derivabile: il gradiente non è utilizzabile. La differential evolution, algoritmo a popolazione, ne cerca il minimo senza bisogno di derivate.

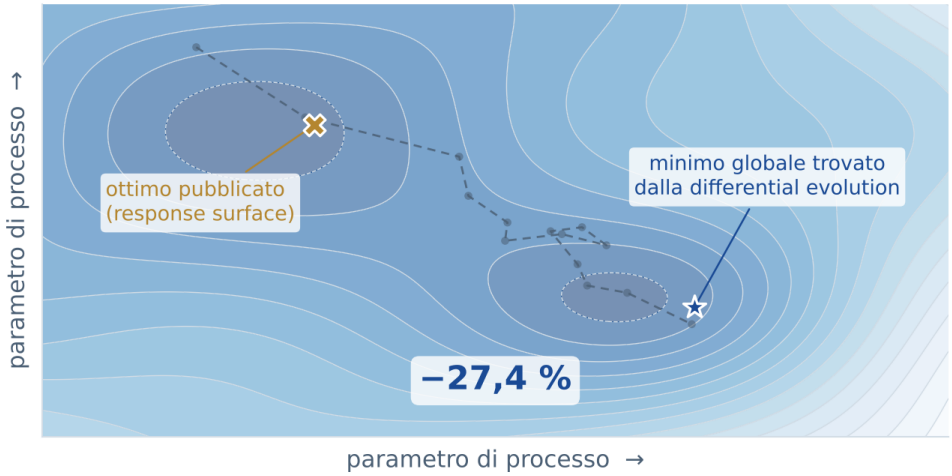


Figura 5 — Il percorso della ricerca sulla superficie appresa, dall'ottimo già pubblicato al minimo globale.

I risultati

- Errore di previsione del 2,33% sul dataset di test
- Il minimo trovato consuma il 27,4% in meno dell'ottimo già pubblicato con la superficie di risposta
- L'architettura accetta indifferentemente dati da FEM, da sensori e da misure sperimentali

Dove sta la decisione

Con un dataset strutturato, regressore e ottimizzatore sono entrambi implementabili. La parte critica è scegliere che cosa ottimizzare: energia, tempo ciclo e picco di forza non si minimizzano insieme, e il compromesso è una decisione aziendale prima che tecnica — ufficio tecnico e produzione insieme. Il minimo che esce va poi sempre verificato con una simulazione o una prova: l'ottimizzatore non sa che cosa sia fattibile in officina.

Caso 3 — L'incertezza: da black box a gray box

Un problema inverso, il più tipico della formatura della lamiera: dato il pezzo imbutito che si vuole ottenere, ricavare la forma del lembo di partenza che lo produce minimizzando difetti e assottigliamento. Si conosce il risultato, non la causa. Tradizionalmente si risolve per tentativi, e ogni tentativo è uno stampo o un lotto di lamiera.



Figura 6 — Un problema inverso risolto una volta sola diventa uno strumento di progettazione estendibile.

Mille simulazioni a mesh adattiva, 23 variabili di ingresso, campionamento Latin hypercube, circa 270 secondi per simulazione. La scelta del modello è qui la vera decisione progettuale: una regressione gaussiana non restituisce soltanto un numero, restituisce anche la deviazione standard di quel numero. Dove esistono campioni vicini la varianza è piccola, dove non ce ne sono cresce.

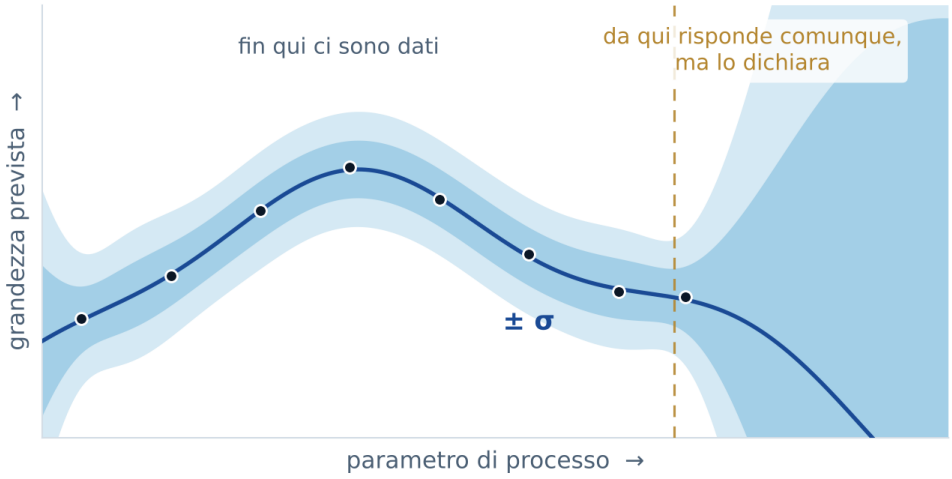


Figura 7 — Dove i dati finiscono la banda si apre: il modello continua a rispondere, ma lo dichiara.

I risultati

- Errore di 0,015 mm sullo spessore previsto, pari all'1,3%, e di 0,12 mm sul raggio esterno, pari allo 0,25%
- Ogni previsione esce accompagnata dalla propria deviazione standard
- Applicato a quattro geometrie flangiate mai simulate, senza riaddestramento

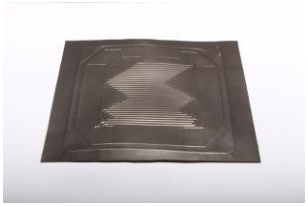
Quando conviene

Quando si producono molte varianti della stessa famiglia di pezzi: il costo è tutto all'inizio e si ammortizza su ogni nuovo codice. Il dataset, peraltro, può nascere collegando il modello FEM a un design of experiments e lasciandolo girare durante il downtime dei server. Resta il limite comune a tutti i modelli data-driven: funziona in interpolazione, e geometrie o materiali radicalmente diversi richiedono un riaddestramento.

Caso 4 — Il know-how: quando i dati non bastano

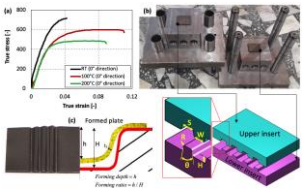
Il quarto caso parte da una condizione che in produzione reale è la norma: pochissimi dati. L'obiettivo è prevedere fino a che profondità si può imbutire una lamiera di titanio commercialmente puro, per pannelli destinati ad alloggiamenti di batterie al litio, prima della frattura. A disposizione ci sono ventiquattro casi in tutto e diciassette variabili: con numeri così un modello puramente statistico non generalizza, e certamente non estrapola.

01 IL COMPONENTE



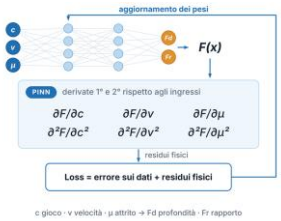
Pannello a serpentina in titanio puro, per alloggiamenti di batterie al litio.

02 LE PROVE



Nove prove sperimentali e quindici simulazioni: ventiquattro casi, diciassette variabili.

03 IL KNOW-HOW



Alla rete neurale si aggiungono equazioni differenziali che traducono il know-how in vincoli.

04 LA PROVA VERA



Il collaudo non è dentro i dati: è su un componente mai visto, la vera estrapolazione.

Figura 8 — Il know-how codificato come pseudo-fisica prende il posto dei dati mancanti.

Non esistendo equazioni differenziali già pronte per questo processo, ne sono state costruite tre, numeriche, sulle tre variabili con importanza più alta fra le diciassette. La backpropagation non minimizza più soltanto l'errore sui dati, ma anche i residui di quelle equazioni.

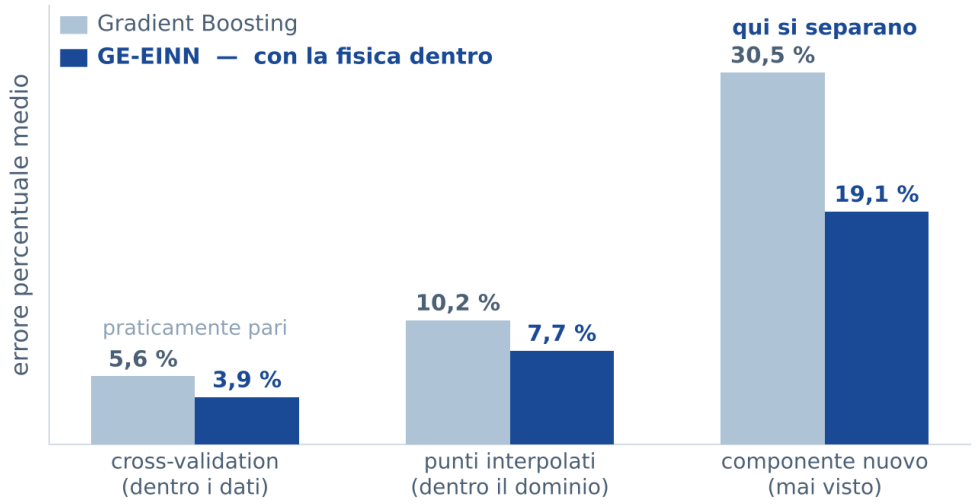


Figura 9 — Errore medio dei due modelli. Dentro i dati sono equivalenti; sul componente mai visto si separano.

I risultati

- Dentro i dati i modelli sono equivalenti: 3,9% in cross-validation contro 5,6% e 5,7%
- Su un componente mai visto il distacco si apre: 19,1% contro il 30,5% del Gradient Boosting
- Le deviazioni standard del modello con la fisica sono molto più piccole: risposte più stabili

Dove sta il lavoro

Nella scrittura delle equazioni di vincolo. Serve il tecnologo di processo, non il programmatore: è la fase più lenta e quella di maggiore valore aggiunto, perché è il momento in cui il know-how aziendale viene trasferito nella modellazione. In compenso ventiquattro casi sono alla portata di qualunque reparto. Il rovescio della medaglia è che il metodo è più lento da mettere a punto di un modello statistico puro: con molti dati a disposizione, spesso conviene il data-driven.

I quattro casi a confronto

	Caso 1	Caso 2	Caso 3	Caso 4
Problema	Previsione	Ottimizzazione	Problema inverso	Dati scarsi
Metodo	Gradient Boosting	XGBoost + metaeuristica	Regressione gaussiana	GE-EINN
Campioni	380 simulazioni	Stesso dataset	1.000 simulazioni	24 fra prove e FEM
Errore	3,18% test / 5,70% prove	2,33% test	1,3% spessore	3,9% cross-validation
Guadagno	Ore → millisecondi	−27,4% di consumo	Incertezza dichiarata	19,1% vs 30,5% fuori dominio

Quattro problemi diversi, la stessa famiglia di metodi. A fare la differenza non è l'algoritmo, ma la definizione dei confini del problema e la qualità dei dati. Il modello, in questo senso, è come l'acqua: prende la forma del contenitore in cui lo si versa — i dati, l'obiettivo, l'incertezza accettabile, il know-how disponibile.

Conclusioni: non è l'algoritmo, è tutto il resto

La domanda che arriva più spesso al termine di una presentazione come questa è quale algoritmo convenga adottare. È la domanda sbagliata, e i quattro casi lo mostrano per via empirica: metodi molto diversi fra loro hanno funzionato bene, ciascuno nel contesto che lo richiedeva. Ciò che ha determinato il risultato è venuto prima della scelta del metodo. Sono quattro condizioni, e nessuna delle quattro si acquista.

Un dataset, non un archivio

Un archivio è un insieme di dati raccolti senza uno scopo preciso; un dataset è una scelta. La differenza non sta nel volume ma nell'intenzione: quali variabili registrare, con quale risoluzione, coprendo quale intervallo. Nel primo caso le 380 simulazioni non sono state recuperate da uno storico, sono state progettate. Prima di cominciare a raccogliere dati conviene sapere a quale domanda dovranno rispondere, perché un archivio ampio ma non progettato produce modelli che interpolano male proprio dove servirebbe.

È anche la ragione per cui la qualità dei dati compare al terzo posto fra gli ostacoli dichiarati dalle imprese italiane, al 45,2%: non è un problema di quantità di informazione disponibile, ma di come è stata raccolta.

Il modello adatto al dato

La scelta del modello conta, ma conta in un modo preciso: influenza il fine tuning e determina che cosa il modello può dire oltre al numero previsto. Non può invece compensare le carenze del dataset. Nel primo caso il Gradient Boosting ha battuto reti neurali e metodi kernel perché il dato era tabellare e relativamente piccolo; nel terzo la regressione gaussiana è stata scelta non perché più accurata, ma perché restituisce anche la propria incertezza. L'applicazione e il dataset determinano quale modello funziona meglio, non viceversa.

Sapere dove finisce il dominio

Tutti i modelli presentati lavorano bene in interpolazione. L'estrapolazione resta un obiettivo complesso, e il punto critico è che un modello data-driven non segnala da solo quando ha superato il confine: continua a produrre numeri plausibili. Il terzo caso mostra una via d'uscita parziale — un modello che dichiara la propria incertezza rende visibile il confine — ma sapere dove il modello sbaglia aiuta a evitare decisioni errate, non risolve il problema di fondo. Il dominio di validità va documentato insieme al modello, e verificato ogni volta che cambia l'impianto, il materiale o la famiglia di pezzi.

Il know-how scritto, non raccontato

È la conclusione meno ovvia delle quattro. Il sapere tecnico di un'azienda esiste quasi sempre in forma orale o procedurale: sta nella testa di chi imposta i processi, e nelle regole pratiche che nessuno ha mai formalizzato. Il quarto caso mostra che quel sapere può essere tradotto in vincoli matematici assegnati al modello, e che così facendo prende il posto di dati che non si hanno. Ventiquattro casi sono diventati sufficienti perché le equazioni del tecnologo hanno colmato il vuoto.

Questo cambia anche chi deve essere coinvolto. La fase a maggiore valore aggiunto non è l'addestramento del modello, che dura minuti, ma la scrittura dei vincoli, che richiede il tecnologo di processo. È la fase più lenta ed è quella in cui il patrimonio aziendale entra davvero nello strumento.

Resta un limite da enunciare con chiarezza: il know-how non è un sostituto dei dati. Nessun modello sarà mai più accurato dei dati su cui si basa, e questo vale anche per il know-how e per il modo in cui viene codificato.

Che cosa significa per un'azienda che fa simulazione oggi

Le quattro condizioni descrivono una posizione di partenza favorevole che molte aziende manifatturiere già possiedono senza averla riconosciuta come tale. Chi fa simulazione da anni ha, di fatto, una fabbrica di dati già installata e un archivio di analisi passate. Chi ha un ufficio tecnico ha il know-how che serve a scrivere i vincoli. Ciò che manca, in genere, è la decisione di trattare quei due patrimoni come materia prima di un modello, e non come sottoprodotti di progetti conclusi.

Vale anche l'inverso. Il 58,6% delle imprese italiane che si sono fermate indica la mancanza di competenze come ostacolo principale: è coerente con quanto visto qui, dove la parte difficile non è mai stata l'algoritmo. FEM, machine learning, dati e know-how non sono quattro scelte alternative fra cui decidere, ma quattro elementi che concorrono alla stessa soluzione ingegneristica.

Una riflessione finale: e se il modello cominciasse a migliorarsi da solo?

Un rapporto pubblicato nel settembre 2026 dalla Shanghai Jiao Tong University con Theseus Labs, Tsinghua e altri, intitolato The Last AI Built by Humans, propone una scala a cinque livelli che misura quanta parte del proprio miglioramento un sistema di AI si prende da solo, e quanta resta in mano a chi lo costruisce.

Livello	Che cosa decide il sistema
L1 — Esecuzione	Esegue gli aggiornamenti decisi dall'uomo
L2 — Strategia	Decide da sé come migliorarsi, dentro obiettivi fissati
L3 — Esperienza	Sceglie quali dati gli servono
L4 — Ambiente	Si adatta al contesto in cui opera
L5 — Lungo termine	Migliora il proprio processo di miglioramento

La scala riguarda sistemi software e agenti, e le applicazioni trattate nel rapporto sono scienza, robotica, software e sanità, non la manifattura. Serve qui per collocare i quattro casi, e la collocazione è netta: siamo al primo livello. In tutti e quattro, il salto di qualità l'ha fatto l'utilizzatore decidendo quale fisica mettere nel modello, su quali variabili, entro quali confini.

Non è una limitazione da superare in fretta. È la descrizione esatta di dove si crea valore oggi: nelle decisioni che restano umane. L'AI, come ogni tecnologia, incide sul nostro modo di lavorare in funzione di come decidiamo di interagirci.

Non si costruisce da soli

I quattro casi presentati nascono tutti da una collaborazione fra università e impresa. Dal 1992 AITeM, l'Associazione Italiana delle Tecnologie Manifatturiere, è la comunità nazionale che tiene insieme università, centri di ricerca e imprese manifatturiere, con quattro obiettivi dichiarati: aggiornamento e diffusione, formazione dei ricercatori, ricerca e innovazione, e trasferimento tecnologico — quest'ultimo come obiettivo a sé, non come sottoprodotto.

Da AITeM nasce HALO-Form (Hybrid Adaptive Learning and Optimization for Forming), un hub di collaborazione dedicato al trasferimento tecnologico in campo AI verso le imprese manifatturiere. Per un'azienda che riconosca nelle quattro condizioni descritte sopra la propria situazione di partenza, è il punto da cui cominciare.

Informazioni

Contatto: Luca Quagliato, Ph.D. — luca.quagliato@unitn.it

Università degli Studi di Trento — Dipartimento di Ingegneria Industriale

Riferimenti

I. Mirandola, G.A. Berti, R. Caracciolo, S. Lee, N. Kim, L. Quagliato, «Machine Learning-Based Models for the Estimation of the Energy Consumption in Metal Forming Processes», Metals 11 (2021) 833.

S. Lee, J. Park, N. Kim, T. Lee, L. Quagliato, «Extreme gradient boosting-inspired process optimization algorithm for manufacturing engineering applications», Materials & Design 226 (2023) 111625.

S. Lee, Y. Lim, L. Galdos, T. Lee, L. Quagliato, «Gaussian process regression-driven deep drawing blank design method», International Journal of Mechanical Sciences 265 (2024) 108898.

V. Modanloo, S. Jang, T. Lee, L. Quagliato, «Gradient Enhanced-Expert Informed Neural Network (GE-EINN) for forming depth prediction from a small-scale metal stamping dataset», Journal of Manufacturing Processes 140 (2025) 224–240.

Y. Duan et al., «The Last AI Built by Humans: Toward Genuine Recursive Self-Improvement», arXiv:2609.11873 (2026).

Dati di contesto: Eurostat, indagine ICT usage in enterprises, dati 2025 (dataset isoc_eb_ai e isoc_eb_ain2), imprese con 10+ addetti · Istat, «Imprese e ICT — Anno 2025» · European Investment Bank, EIB Investment Survey 2025 · Osservatorio Artificial Intelligence, Politecnico di Milano, Ricerca 2025.