

Applicazione dei modelli di apprendimento automatico per la classificazione delle malattie che richiedono il ricovero ospedaliero: un approccio basato sul NOM-035 e sull'economia sociale e solidale in Messico





Aplicación de modelos de aprendizaje automático para la clasificación de enfermedades con requerimiento hospitalario: un enfoque basado en la NOM-035 y la Economía Social y Solidaria en México

Lara-Escamilla, Samuel *^a, Rodríguez-Molina, Alejandro^b, Rueda-Gutiérrez, Allan Balam^c e Salazar-Cano, Nellie Cecilia^d

^a  Instituto Tecnológico de Tlalnepantla •  ABE-1839-2022 •  0000-0002-2337-0878 •  609026

^b  Universidad Autónoma de la Ciudad de México •  AAY-9817-2020 •  0000-0002-6901-3833 •  555081

^c  Instituto Tecnológico de Tlalnepantla •  OJV-4600-2025 •  0009-0002-1887-8148 •  295451

^d  Instituto Tecnológico de Durango •  OQK-6707-2025 •  0009-0004-9189-7251 •  672635

Classificazione:

DOI: <https://doi.org/10.35429/P.2025.1.89.100>

Area: Ingegneria

Settore: Scienze tecnologiche

Disciplina: Tecnologia informatica

Sottodisciplina: Intelligenza artificiale

Punti chiave del manuale

Tra i principali contributi alla generazione di scienza e tecnologia descritti in questa ricerca figurano: innovazione metodologica, applicazione interdisciplinare, progressi nella previsione medica, approccio etico e sociale. Gli aspetti principali da applicare alla generazione di conoscenza universale sono: integrazione transdisciplinare, poiché integra scienza dei dati, medicina, psicologia del lavoro ed economia solidale, favorendo la costruzione di una conoscenza universale applicabile a diversi contesti sociali. Etica nell'implementazione della tecnologia: dimostra che l'IA può essere utilizzata in modo responsabile, dando priorità all'equità e al benessere umano. Solida base empirica: garantendo la replicabilità dei dati, sostiene la generazione di conoscenza scientifica attraverso la validazione incrociata, le metriche quantitative e l'analisi di sensibilità. Prospettiva di sostenibilità: promuove lo sviluppo di sistemi predittivi che integrano dati biomedici e psicosociali per rafforzare la salute occupazionale globale. Gestione degli ospedali e dei sistemi sanitari: favorisce la classificazione e la categorizzazione dei pazienti in base alle entrate, riducendo i tempi di attesa e contribuendo alle diagnosi cliniche a beneficio della popolazione e della salute. Le conclusioni di questa ricerca sono: la fattibilità di applicare modelli di apprendimento automatico, in particolare MLP e SVM, come strumenti di supporto nel processo decisionale medico per raccomandare il ricovero in ospedale sulla base di dati fisiologici e psicosociali. Entrambi i modelli hanno raggiunto metriche superiori al 90% in termini di accuratezza, precisione e sensibilità, convalidando il loro potenziale predittivo per ottimizzare la gestione ospedaliera. Il metodo integra le linee guida della NOM-035-STPS-2018, incorporando fattori psicosociali e organizzativi, e si inserisce nei principi dell'Economia Sociale e Solidale [ESS], promuovendo sistemi di intelligenza artificiale etici e orientati al benessere collettivo. Si propone di ampliare la banca dati e di includere nuove variabili psicologiche, ambientali e lavorative per rafforzare la capacità predittiva e l'interpretabilità del modello verso un sistema sanitario integrale sostenibile. Gli autori di questa ricerca appartengono al SNII, uno ha una borsa di studio del SECIIHTI e uno appartiene al sistema PRODEP. I docenti che hanno contribuito sono affiliati a istituti di istruzione superiore del sistema di istruzione pubblica: Tecnológico Nacional de México Tlalnepantla, Universidad Autónoma de la Ciudad de México, Tecnológico Nacional de México Durango.

Area: Advocacy e attenzione ai problemi nazionali

Citazione: Lara-Escamilla, Samuel, Rodríguez-Molina, Alejandro, Rueda-Gutiérrez, Allan Balam e Salazar-Cano, Nellie Cecilia. 2025. Applicazione dei modelli di apprendimento automatico per la classificazione delle malattie che richiedono il ricovero ospedaliero: un approccio basato sul NOM-035 e sull'economia sociale e solidale in Messico. 89-100. PIREQA.

* ✉ [\[samuel.le@tlalnepantla.tecnm.mx\]](mailto:samuel.le@tlalnepantla.tecnm.mx)

URL dello scaffale del manuale: <https://www.pireqa.org/proceedings.php>



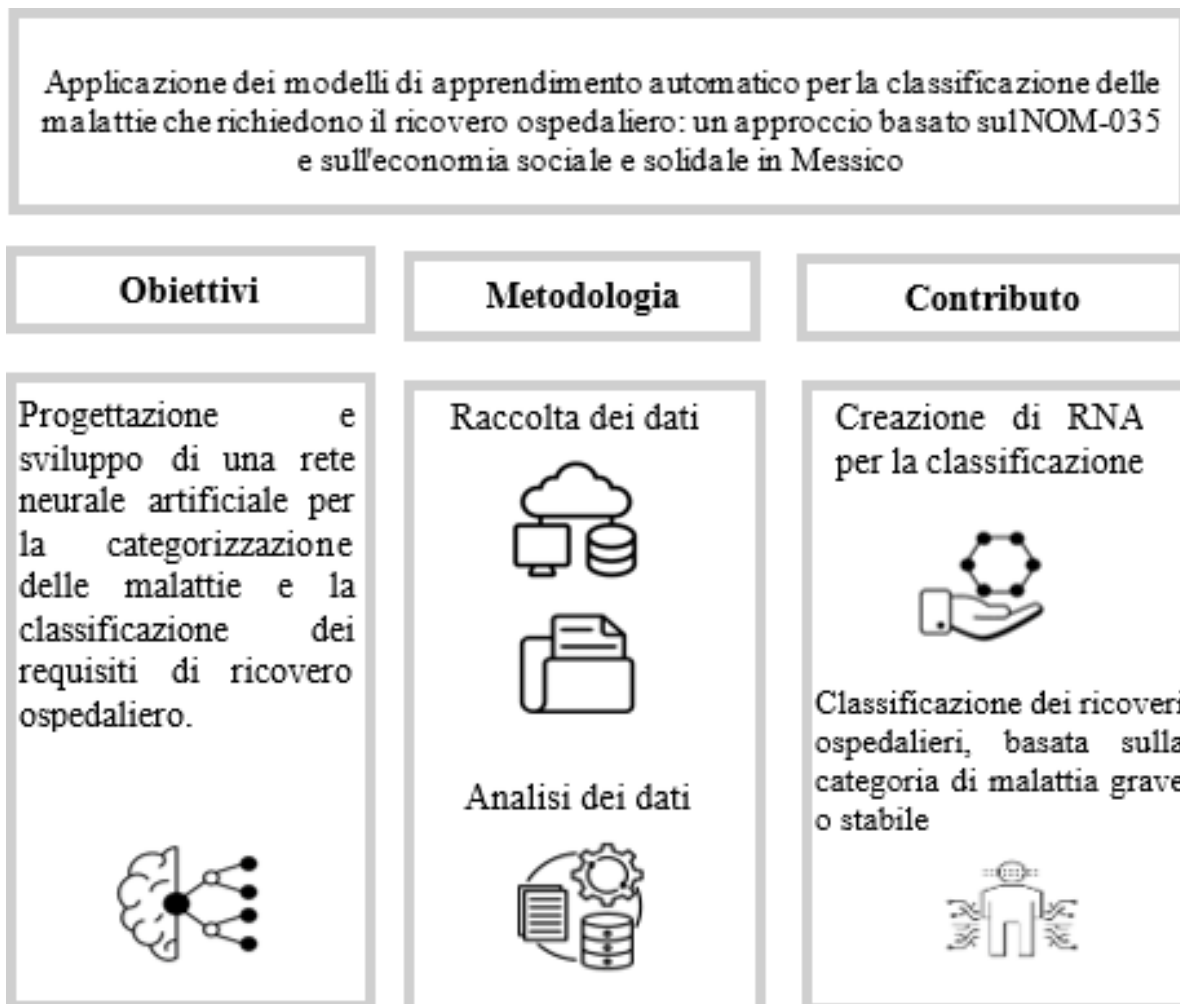
ISBN 978-607-8948-70-3 /©2009 Autore/i. Pubblicato da PIREQA-México, S.C. per la sua Holding Mexico per conto dell'Proceeding PIINI. Questo è un libro ad accesso libero con licenza CC BY-NC-ND [<http://creativecommons.org/licenses/by-nc-nd/4.0/>]

Revisione tra pari sotto la responsabilità del Comitato Scientifico MARVID®- nel contributo al processo di revisione tra pari in ambito scientifico, tecnologico e dell'innovazione attraverso la formazione delle risorse umane per la continuità nell'analisi critica della ricerca internazionale.



Sommario


Questo articolo analizza l'uso di modelli predittivi di apprendimento automatico, in particolare reti neurali artificiali [ANN] e macchine a vettori di supporto [SVM], per raccomandare il ricovero ospedaliero tenendo conto di fattori psicosociali e clinici, nel quadro della NOM-035-STPS-2018 e dei principi dell'economia sociale e solidale [ESS]. Il suo obiettivo è quello di evitare ricoveri ospedalieri non necessari derivanti da indicatori isolati, identificando combinazioni di fattori che giustificano l'assistenza ospedaliera. Utilizzando un approccio quantitativo e predittivo, i dati medici, psicosociali e sociodemografici sono stati elaborati con operatori logici e ricerca operativa, ottenendo sei indicatori di rischio. Sono stati addestrati un perceptron multistrato [MLP] e una SVM con funzione di base radiale [RBF], entrambi con un'elevata accuratezza nella classificazione binaria relativa al ricovero ospedaliero. I modelli proposti sono consolidati come strumenti di supporto per il processo decisionale medico e l'ottimizzazione delle risorse ospedaliere.



Reti neurali artificiali, macchine a vettori di supporto, intelligenza artificiale nel settore sanitario

Resumen

El artículo analiza el uso de modelos predictivos de aprendizaje automático, específicamente redes neuronales artificiales [RNA] y máquinas de soporte vectorial [SVM], para recomendar hospitalización médica considerando factores psicosociales y clínicos, en el marco de la NOM-035-STPS-2018 y los principios de la Economía Social y Solidaria [ESS]. Su objetivo es evitar hospitalizaciones innecesarias derivadas de indicadores aislados, identificando combinaciones de factores que justifiquen la atención hospitalaria. Con un enfoque cuantitativo y predictivo, se usaron datos médicos, psicosociales y sociodemográficos procesados con Operadores Lógicos e investigación operativa, obteniendo seis indicadores de riesgo. Se entrenaron un Perceptrón Multicapa [MLP] y una SVM con función de base radial [RBF], alcanzando ambos alta precisión en la clasificación binaria sobre hospitalización. Los modelos propuestos se consolidan como herramientas de apoyo para la toma de decisiones médicas y la optimización de recursos hospitalarios.



Rdes neuronales artificiales; máquinas de soporte vectorial; inteligencia artificial aplicada a la salud

1. Introduzione

L'uso dell'intelligenza artificiale [IA] e dell'apprendimento automatico ha acquisito rilevanza negli ultimi anni come strumento analitico nella medicina predittiva e nella salute sul lavoro [Goodfellow, Bengio, & Courville, 2016; LeCun & Hinton, 2015]. Tra le tecniche più importanti in questo campo figurano le RNA e le SVM, poiché consentono di identificare modelli complessi e di effettuare classificazioni accurate in contesti in cui i metodi statistici tradizionali presentano dei limiti [Nwanosike, E. M., Conway, B. R., Merchant, H. A., & Hasan, S. S., 2022].

La saturazione degli ospedali in Messico e in molti altri paesi è un problema importante, attribuito in molti casi al ricovero di pazienti sulla base di sintomatologia e indicatori clinici isolati [Cisterna-García, A., Guillén-Teruel, A., Caracena, M., Pérez, E., Jiménez, F., Francisco-Verdú, F. J., & Botía, J. A., 2022]. Tuttavia, il ricovero dei pazienti non sempre può essere giustificato con queste informazioni. La mancanza di strumenti che valutino l'impatto dei diversi indicatori clinici, oltre ai fattori psicosociali e sociodemografici, provoca azioni mediche che riducono l'efficienza del sistema sanitario.

In questo contesto, la norma messicana NOM-035-STPS-2018 regola i fattori di rischio psicosociale nei luoghi di lavoro, riconoscendo che lo stress, il carico di lavoro e la mancanza di sostegno sociale hanno un impatto diretto sulla salute fisica e mentale dei lavoratori [Segreteria del Lavoro e della Previdenza Sociale, 2018]. D'altra parte, l'Economia Sociale e Solidale [ESS] propone un modello di gestione partecipativa orientato a generare benessere collettivo, che apre la possibilità di incorporare tecnologie di intelligenza artificiale come strumenti di rafforzamento della comunità.

Per quanto sopra, il presente lavoro propone lo sviluppo di modelli di apprendimento automatico, in particolare Perceptrons Multicapa [MLP] e macchine a supporto vettoriale [SVM], per raccomandare il ricovero dei pazienti quando la combinazione di variabili fisiologiche chiave, gli indicatori psicosociali della NOM-035 e i principi dell'ESS suggeriscono che esiste un rischio elevato per la salute.

2. Metodologia

2.1. Approccio e progettazione

È stato adottato un approccio quantitativo, esplicativo e predittivo, basato su una progettazione non sperimentale e trasversale. L'obiettivo era quello di sviluppare e convalidare i modelli di apprendimento automatico per raccomandare il ricovero in ospedale dei pazienti con elevati rischi per la salute.

Il modello formula le raccomandazioni sulla base di una classificazione binaria supervisionata relativa alle caratteristiche legate alle variabili cliniche e psicosociali, evitando ricoveri non necessari dovuti a indicatori isolati [ad esempio, pressione alta o glicemia elevata].

2.2. Set di dati originale

È stato utilizzato un set di dati denominato Dataset.csv composto da 500 e 1000 osservazioni, che è servito come base per la modellizzazione e la classificazione dello stato di ricovero ospedaliero codificato in formato binario [1 = ricoverato, 0 = non ricoverato].

Le osservazioni includono: età, sesso, indice di massa corporea [IMC]; misurazioni di pressione sistolica, pressione diastolica, colesterolo totale e glucosio; oltre a informazioni quali livello di attività fisica, consumo di tabacco, diabete e storia familiare di malattie. Questo database è stato scelto perché è rappresentativo e coerente con i fattori di rischio che la NOM-035-STPS-2018 associa allo stress lavorativo e al deterioramento della salute fisica. Si è cercato di utilizzare informazioni biomediche reali per costruire un sistema di supporto alle decisioni mediche che fosse conforme ai principi dell'ESS.

2.3. Modellizzazione logico-matematica e trasformazione delle variabili

Prima dell'addestramento dei modelli di apprendimento automatico, è stato applicato un processo di modellizzazione logico-matematica basato sulla ricerca operativa [IO] per trasformare i valori clinici originali in sei variabili derivate, che rappresentano indicatori composti di rischio clinico e psicosociale.

Lo scopo era quello di costruire variabili derivate che rappresentassero in modo più coerente le interazioni tra i fattori fisiologici e le condizioni di rischio associate al ricovero ospedaliero.

2.3.1 Classificazione e categorizzazione delle variabili

Le variabili originali nel set di dati sono state raggruppate in base alla loro natura e al tipo di misurazione, come illustrato nella Tabella 1, facilitando la codifica e la progettazione di regole logiche di combinazione. I valori soglia sono stati definiti in base ai parametri stabiliti dall'Organizzazione Mondiale della Sanità [OMS]. Ad esempio, un valore di glucosio ≥ 125 mg/dL è stato codificato come 1 [rischio elevato], mentre un valore < 100 mg/dL è stato considerato normale [0].

Scatola 1

Tabella 1

Strutture di codifica utilizzate

Categoria	Esempi	Tipo	Codifica
Sociodemografiche	Età, sesso, anzianità di servizio,	Nominale	One-hot
Diagnosi medica	tipo di organizzazione	Continuo	Normalizzazione /Binarizzazione
Psicosociali [NOM-035]	Pressione arteriosa, glucosio,	Ordinale	0-1-2

2.3.2. Conversione e codifica numerica

Successivamente, le variabili categoriali sono state convertite in numeriche utilizzando un dizionario di equivalenze elaborato in Excel con le funzioni *CERCA.VERT[]* e *SE[]*, e convalidato in Python tramite *LabelEncoder* e *OneHotEncoder*. Ciò ha permesso di elaborare le variabili qualitative all'interno del modello matematico e tramite le librerie di *scikit-learn*.

2.3.3 Operatori logici e restrizioni lineari

Al fine di rappresentare le combinazioni di rischio tra le variabili fisiologiche, sono stati utilizzati operatori logici [AND, OR, XOR, NAND, NOR], espressi tramite restrizioni lineari che ne consentono l'implementazione in *Solver* di Excel, come mostrato nella Tabella 2.

Scatola 2

Tabella 2

Strutture di codifica utilizzate

Operatore	Espressione logica	Restrizioni
AND	$z = x \wedge y$	$z \leq x; z \leq y; z \geq x + y - 1$
OR	$z = x \vee y$	$z \geq x; z \geq y; z \leq x + y$
XOR	$z = x \oplus y$	$z = x + y - 2[x \cdot y]$
NAND	$\neg[x \wedge y]$	$z = 1 - [x \cdot y]$
NOR	$\neg[x \vee y]$	$z = 1 - [x + y]$

Queste operazioni sono state applicate per modellare condizioni quali, ad esempio:

- OR: rischio metabolico se il glucosio è alto o la pressione è elevata.
- AND: rischio cardiovascolare se il glucosio è alto e la pressione è elevata.
- NAND: assenza di rischio quando non coesistono condizioni critiche.

Il *Solver* di Excel, utilizzando i metodi GRG Non Lineare ed Evolutivo, ha ottimizzato le soglie dinamiche di queste combinazioni per minimizzare l'errore quadratico medio [ECM] e massimizzare l'*F1-score* tra la diagnosi reale e quella prevista.

Il risultato di questo processo è stata la generazione di sei variabili binarie derivate, che rappresentano indicatori di rischio clinico e psicosociale, formate dall'uso di soglie e combinazioni logiche tra le variabili originali, inclusa la variabile obiettivo che indica se un paziente deve essere ricoverato in ospedale o meno. Queste variabili sono: presenza di malattia, pressione alta, pressione bassa, glucosio alto, glucosio basso e necessità di ricovero ospedaliero.

La Figura 1 mostra un esempio della variabile che denota la presenza di una malattia in contrasto con le variabili del glucosio e della pressione sistolica. Ogni punto rappresenta una singola cartella clinica, classificata in base alla diagnosi medica [sano o malato]. Si osserva una moderata sovrapposizione tra le due classi, che giustifica l'uso di modelli non lineari, come l'MLP e l'SVM, in grado di definire confini decisionali complessi, come quelli utilizzati nelle fasi successive.

Scatola 3

Distribuzione del glucosio rispetto alla pressione sistolica Classificazione per malattia.




Figura 1

Distribuzione dei pazienti malati nello spazio formato dalle variabili glicemia e pressione sistolica.

Fonte: elaborazione propria

2.4. Preparazione del set di dati finale

Le sei variabili derivate sono state combinate con le informazioni originali per formare il set di dati finale. Successivamente, le variabili numeriche sono state normalizzate utilizzando *StandardScaler* di Python e la variabile sesso è stata codificata come binaria. Successivamente, il set è stato suddiviso in 70% per l'addestramento e 30% per il test, utilizzando *train_test_split* con partizione stratificata per mantenere la proporzione tra le classi. Questo set è stato utilizzato per addestrare i modelli MLP e SVM nelle stesse condizioni.

2.5. Modelli di classificazione binaria

2.5.1. Rete neurale artificiale

Il modello RNA implementato era un Perceptron Multilayer [*MLPClassifier*] con uno strato nascosto di otto neuroni e un massimo di 5000 iterazioni per la sua regolazione [[Pedregosa et al., 2011](#)]. L'addestramento è stato eseguito nell'ambiente Python utilizzando la libreria scikit-learn, applicando la convalida incrociata per garantire la coerenza dei risultati e ridurre il rischio di sovradattamento [[Zhang, J., Liu, S., & Wang, Y., 2008](#)].

Il processo di apprendimento è stato effettuato utilizzando l'algoritmo di retropropagazione dell'errore, regolando i pesi sinaptici fino a minimizzare la funzione di perdita definita sull'insieme di addestramento. Le prestazioni del modello sono state valutate utilizzando le metriche standard di classificazione: accuratezza [*accuracy*], sensibilità [*recall*], precisione positiva [*precision*] e *F1-score*, integrate con la matrice di confusione per identificare la distribuzione di successi ed errori per classe [[Musaa, F. E., & Elnoor, E. M., 2025](#)].

2.5.2. Macchine a supporto vettoriale

Oltre alla RNA, è stata utilizzata una SVM che impiega un nucleo con funzione di base radiale [RBF] [Razaque, A., Ben Haj Frej, M., Almi'ani, M., Alotaibi, M., & Alotaibi, B., 2021].

L'implementazione è stata effettuata utilizzando la classe SVC del pacchetto scikit-learn [Pedregosa et al., 2011], integrando StandardScaler nel flusso di lavoro per la normalizzazione automatica delle variabili prima dell'adattamento del modello.

Come per l'MLP, è stata applicata la validazione incrociata stratificata, assicurando che ogni piega mantenesse la proporzione originale delle classi.

Al fine di trovare la configurazione ottimale del modello, è stata effettuata una ricerca sistematica degli iperparametri, variando i valori di nell'intervallo e di in . In questo modo, è stata esplorata la combinazione completa di e , registrando le prestazioni medie in ogni punto della griglia.

3. Risultati e discussione

3.1. Comportamento del modello MLP

La Figura 2 presenta la matrice di confusione ottenuta per il modello neurale MLP.

Il risultato evidenzia una distribuzione equilibrata tra veri positivi [VP] e veri negativi [VN], con un numero ridotto di errori di classificazione [dati da FP e FN]. Questo comportamento riflette il fatto che il modello riesce a identificare correttamente la maggior parte dei pazienti che necessitano di ricovero ospedaliero, mantenendo un equilibrio tra sensibilità e specificità.

Scatola 4




Figura 2

Matrice di confusione del modello MLP.

Fonte: elaborazione propria

Sulla base di questi valori, sono state calcolate le principali metriche di prestazione riportate nella Tabella 3. Questi risultati mostrano che l'MLP ha raggiunto un'accuratezza del 91,3%, con un equilibrio tra precisione e sensibilità, garantendo una risposta affidabile sia nell'individuazione dei pazienti ricoverati in ospedale che nella corretta identificazione di quelli non ricoverati.

Il modello ha dimostrato robustezza di fronte a lievi variazioni nei dati e capacità di cogliere relazioni non lineari tra le variabili derivate dalla modellizzazione logico-matematica. Le sue prestazioni suggeriscono che può essere applicato efficacemente in contesti in cui le cartelle cliniche includono interdipendenze o lievi livelli di rumore, come cartelle incomplete o variabili con elevata correlazione clinica.

Scatola 5

Tabella 3

Prestazioni del modello MLP.

Metrica	Valore [%]
Accuratezza	91.3
Precisione	92.0
Richiamo	90.9
Punteggio F1	91.4

La performance complessiva dell'MLP è illustrata nella Figura 3, dove sono riportate le metriche precedenti. La figura mostra un comportamento equilibrato tra le diverse misure, con valori superiori al 90%, che indicano una performance stabile e coerente nella classificazione dei pazienti.

Scatola 6




Figura 3

Andamento dell'MLP illustrato tramite un grafico a barre.

Fonte: elaborazione propria

3.2. Comportamento del modello SVM

La Figura 4 corrisponde alla matrice di confusione generata con le previsioni del modello SVM con nucleo RBF, utilizzando $C=1$. Il modello ha ottenuto una separazione perfetta tra le classi, senza errori di classificazione apparenti, il che suggerisce un adeguato adattamento degli iperparametri nelle condizioni del set di dati.

Scatola 7

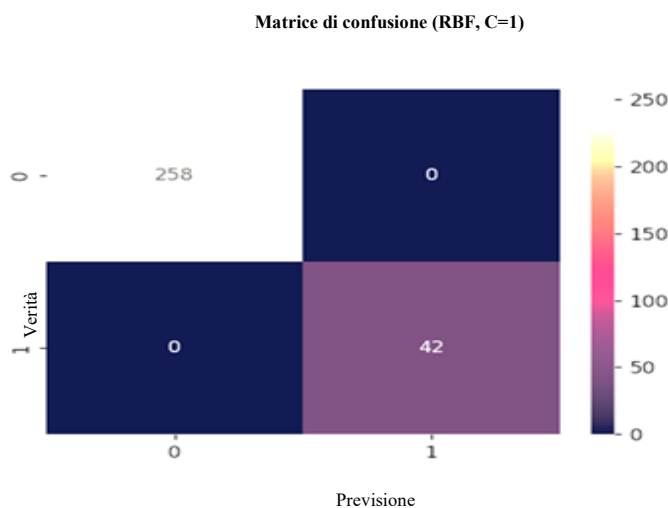


Figura 4

Matrice di confusione del modello SVM con nucleo radiale.

Fonte: elaborazione propria

Le metriche di prestazione derivate dalla Figura 2 sono riportate nella Tabella 4. Sulla base di questi valori, il modello SVM ha evidenziato un confine decisionale altamente definito, ottenendo previsioni accurate in entrambi i gruppi [ricoverati e non ricoverati]. Questa precisione è associata alla capacità del nucleo RBF di proiettare le variabili in uno spazio di maggiore dimensionalità, dove i confini tra le classi diventano linearmente separabili.

Tuttavia, il raggiungimento di una performance perfetta potrebbe essere influenzato dalla struttura e dall'equilibrio del set di dati, pertanto si raccomanda di valutare il modello in nuove partizioni o con dati esterni prima della sua applicazione in ambienti clinici reali. Ciononostante, il risultato dimostra che l'SVM-RBF costituisce uno strumento efficiente e preciso per compiti di classificazione medica in scenari con interazioni non lineari e un numero limitato di registrazioni.

Scatola 8

Tabella 4

Prestazioni del modello SVM

Metrica	Valore [%]
Accuratezza	100.0
Precisione	100.0
Richiamo	100.0
Punteggio F1	100.0

Figura 5 mostra la rappresentazione bidimensionale del confine decisionale generato dalla SVM con nucleo radiale RBF. È stata utilizzata la coppia di variabili pressione sistolica e glucosio per visualizzare il confine tra pazienti ospedalizzati e non ospedalizzati. Si osserva che il classificatore ottiene una separazione morbida e precisa tra le due regioni, catturando adeguatamente le relazioni non lineari presenti nei dati.

Scatola 9




Figura 5

Confine decisionale del modello SVM con nucleo radiale [RBF] considerando le variabili glucosio e pressione sistolica.

Fonte: elaborazione propria

3.4. Considerazioni sull'uso di MLP e SVM come strumenti alternativi

Anziché stabilire un confronto diretto tra i modelli, se ne propone l'uso come strumenti alternativi e complementari all'interno dello stesso quadro di analisi predittiva. Entrambi i modelli hanno dimostrato la capacità di elaborare le variabili derivate dalla modellizzazione logico-matematica, sebbene ciascuno presenti vantaggi, limiti e considerazioni d'uso specifici, riassunti nella Tabella 5.

Scatola 10**Tabella 5**

Aspetti da tenere in considerazione sull'uso dei modelli MLP e SVM.

Aspetto	MLP	SVM
Natura del modello	Apprendimento adattivo, basato sui pesi sinaptici	Modello strutturato, basato su vettori di supporto
Tipo di relazione rilevata	Non lineare, complesso, dipendente dalla regolazione dei pesi	Lineare o non lineare, controllato dal nucleo
Vantaggi	Generalizzazione progressiva, tollerante al rumore, interpretabile in strati	Buona precisione con meno dati, evita il sovradimensionamento, efficiente in dimensioni elevate
Limiti	Richiede una regolazione fine dei parametri [numero di neuroni, tasso di apprendimento]	Sensibile alla selezione di C e γ . Può essere costoso in grandi insiemi di dati.
Applicazione suggerita	Scenari con elevata variabilità nelle registrazioni cliniche	Scenari con dati più strutturati o linearmente separabili

Pertanto, l'MLP è consigliabile in situazioni in cui le relazioni tra le variabili sono diffuse, ad esempio dati con interazione tra fattori clinici e psicosociali, mentre l'SVM è appropriato in contesti in cui è richiesta una classificazione accurata con minore complessità computazionale.

3.5. Implicazioni cliniche e computazionali

Entrambi i modelli contribuiscono alla costruzione di un sistema di supporto alle decisioni mediche orientato a raccomandare il ricovero ospedaliero in modo razionale, sulla base della combinazione di variabili cliniche e psicosociali. Questo approccio può prevenire ricoveri ospedalieri non necessari, dando priorità ai rischi reali delle persone e promuovendo un uso solidale delle risorse in base ai principi dell'ESS e della NOM-035-STPS-2018.

Dal punto di vista computazionale, il processo di addestramento e convalida può essere facilmente incorporato nei sistemi clinici digitali, in modo che il personale medico possa selezionare correttamente il modello più appropriato [MLP o SVM] in base alle caratteristiche del paziente o dell'ambiente operativo.

4. Conclusioni

Il presente articolo espone la fattibilità di implementare modelli di apprendimento automatico come strumenti per facilitare il processo decisionale medico. In questo senso, i modelli MLP e SVM sono proposti come un possibile strumento di supporto per formulare raccomandazioni sul ricovero di un paziente attraverso l'uso e l'integrazione di dati fisiologici e psicosociali.

I modelli MLP e SVM hanno raggiunto metriche superiori al 90% in termini di accuratezza, precisione e sensibilità, che hanno convalidato il loro potenziale predittivo per assistere nel processo decisionale medico e contribuire a un migliore utilizzo dell'assegnazione delle risorse ospedaliere.

Il metodo proposto incorpora gli indicatori della NOM-035-STPS-2018 per estendere l'analisi oltre i parametri clinici, considerando le dimensioni psicosociali e organizzative del rischio lavorativo. Dal punto di vista dell'EES, i risultati confermano la fattibilità di sviluppare sistemi di intelligenza artificiale o apprendimento automatico etici, riproducibili e socialmente orientati, utili per il sistema sanitario.

Infine, si propone di ampliare la banca dati e di incorporare nuove variabili psicologiche, ambientali e occupazionali che rafforzino la capacità predittiva e l'interpretabilità del modello. Queste azioni consentiranno di avanzare verso un sistema sanitario integrale e sostenibile, che colleghi l'IA al benessere umano.

Dichiarazioni**Conflitto di interessi**

Gli autori dichiarano di non avere alcun conflitto di interessi. Non hanno interessi finanziari concorrenti noti né relazioni personali che potrebbero influenzare l'articolo riportato in questo articolo.

Contributo degli autori

Lara-Escamilla, Samuel: ho fornito l'idea principale del progetto, ho contribuito concettualmente e allo sviluppo metodologico e con tecniche di ricerca per l'acquisizione dei dati, la programmazione e l'addestramento della RNA

Rodríguez-Molina, Alejandro: Ho contribuito alla ricerca concettuale nell'analisi della rete neurale del progetto con metodologia di ricerca per la progettazione, l'addestramento, la convalida del modello e la progettazione della rete neurale artificiale, e ho fornito un contributo tecnico nella redazione

Rueda-Gutiérrez, Allan Balam: Ho effettuato la valutazione delle RNA, la matrice di confusione, nonché la valutazione dei valori di progettazione.

Salazar-Cano, Nellie Cecilia: Collaboro alla redazione e alla traduzione dei documenti.

Disponibilità di dati e materiali

Tutti i dati sono disponibili sui siti web ufficiali.

Finanziamento

La ricerca non ha ricevuto alcun finanziamento.

Ringraziamenti

Indicare se sono stati finanziati da qualche istituzione, università o azienda.

Abbreviazioni

A	Accuratezza
AI	Intelligenza artificiale
ANN	Rete neurale artificiale
DL	Deep learning
FCN	Falso negativo
FN	Falso positivo
FP	Rete neurale
OSSE	Organismi del settore sociale dell'economia
P	Precisione
R	Richiamo
S	Sensibilità

Riferimenti

Fondamentali

Cisterna-García, A., Guillén-Teruel, A., Caracena, M., Pérez, E., Jiménez, F., Francisco-Verdú, F. J., ... & Botía, J. A. [2022]. [A predictive model for hospitalization and survival to COVID-19 in a retrospective population-based study](#). *Scientific Reports*, 12[1], 18126.

Supporto

Cooper, C. L., Quick, J. C., & Schabracq, M. J. [2015]. [International Handbook of Work and Health Psychology](#) [3rd ed.]. Wiley-Blackwell.

LeCun, Y., & Hinton, G. [2015]. [Deep learning](#). *Nature*, 521[7553], 436–444.

Antecedenti

Secretaría del Trabajo y Previsión Social [STPS]. [2018]. [NOM-035-STPS-2018: Factores de riesgo psicosocial en el trabajo. Identificación, análisis y prevención](#). Diario Oficial de la Federación.

Supporto

Goodfellow, I., Bengio, Y., & Courville, A. [2016]. [Deep Learning](#). MIT Press.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., & Duchesnay, É. [2011]. [Scikit-learn: Machine learning in Python](#). *Journal of Machine Learning Research*, 12, 2825–2830.

World Health Organization. [2022]. [Workplace Health Promotion and Well-being](#). WHO Publications.

Zhang, J., Liu, S., & Wang, Y. [2008]. [Gene association study with SVM, MLP and cross-validation for the diagnosis of diseases](#). *Progress in Natural Science*, 18[6], 741-750

Differenze

Musaa, F. E., & Elnoor, E. M. [2025]. [A Comparative Study of Machine Learning Algorithms for Lung Cancer Diagnosis: Evaluating Performance Using ROC Curve, Accuracy, Recall, and F1 Score Metrics](#). *General Letters in Mathematics [GLM]*, 15[2].

Razaque, A., Ben Haj Frej, M., Almi'ani, M., Alotaibi, M., & Alotaibi, B. [2021]. [Improved support vector machine enabled radial basis function and linear variants for remote sensing image classification](#). *Sensors*, 21[13], 4431

Discussioni

Nwanosike, E. M., Conway, B. R., Merchant, H. A., & Hasan, S. S. [2022]. [Potential applications and performance of machine learning techniques and algorithms in clinical practice: a systematic review](#). *International journal of medical informatics*, 159, 104679.

Secretaría del Trabajo y Previsión Social [STPS]. [2018]. NOM-035-STPS-2018: [Factores de riesgo psicosocial en el trabajo. Identificación, análisis y prevención](#). *Diario Oficial de la Federación*.

World Health Organization. [2022]. [Workplace Health Promotion and Well-being](#). WHO Publications.

Zhang, J., Liu, S., & Wang, Y. [2008]. [Gene association study with SVM, MLP and cross-validation for the diagnosis of diseases](#). *Progress in Natural Science*, 18[6], 741-750