



UNIVERSITA' POLITECNICA DELLE MARCHE

FACOLTA' DI INGEGNERIA

Corso di Laurea triennale in INGEGNERIA GESTIONALE

INTELLIGENZA ARTIFICIALE NELL'INDUSTRIA 4.0

ARTIFICIAL INTELLIGENCE IN INDUSTRY 4.0

Relatore: Chiar.mo/a

Tesi di Laurea di:

Prof. **MAURIZIO BEVILACQUA**

ROMAGNOLI GIULIO

Correlatore: Chiar.mo/a Prof.

GIOVANNI MAZZUTO

A.A. 2021 / 2022

INDICE

1. INTRODUZIONE	1
2. INTELLIGENZA ARTIFICIALE	2
2.1 Definizione	2
3. MACHINE LEARNING	4
3.1 Definizione	4
3.2 Tipi di machine learning	5
3.3 Classificazione	6
3.4 Regressione	7
3.5 Clustering	8
3.6 Reti neurali	8
3.6.1 Neurone MCP.....	9
3.6.2 Perceptron.....	10
3.6.3 Adaline.....	11
3.6.4 Discesa del gradiente.....	12
3.6.5 Discesa stocastica del gradiente.....	14
3.6.6 Funzione di attivazione sigmoide.....	15
3.7 Anomaly detection	16
3.7.1 Metodi basati su distanza.....	21
3.7.2 Metodi basati su modelli.....	23
3.7.3 Metodi basati su reti neurali.....	24
3.8 Support Vector Machine SVM	26
4. APPLICAZIONI	28
4.1 Un supporto decisionale alla gestione delle modifiche ingegneristiche nell'industria automobilistica	28
4.1.1 Caso di studio.....	28
4.1.2 Soluzione proposta.....	29
4.1.3 Algoritmo Random Forest.....	30
4.2 Modelli di valutazione della sicurezza antincendio per l'industria del carbone ...31	
4.2.1 Caso di studio.....	31
4.2.2 Trattamento dei dati ottenuti tramite classificatore Naive Bayes.....	32
4.2.3 Trattamento dei dati ottenuti con il metodo SVM.....	34
4.2.4 Conclusioni.....	35
4.3 Un modello per la gestione della supply chain	36

4.3.1 Caso di studio	36
4.3.2 Connessione e collaborazione di rete per la supply chain.....	37
4.3.3 Metodo di selezione dinamica dei partner della catena di approvvigionamento ...	39
4.3.4 Conclusioni	41
4.4 Modelli predittivi per il rilevamento del COVID-19	43
4.4.1 Caso di studio	43
4.4.2 Selezione delle caratteristiche informative per l'esame del sangue	45
4.4.3 Metodi di machine learning applicati	45
4.4.4 Conclusioni	48
BIBLIOGRAFIA	49
RINGRAZIAMENTI.....	51

1. INTRODUZIONE

La quarta rivoluzione industriale (Industria 4.0) è basata su una crescente integrazione di “sistemi cyber-fisici” (cyber-physical systems o CPS) nei processi industriali. Con l’Industria 4.0 i sistemi industriali ed i relativi macchinari sono sempre più dotati di tecnologie che acquisiscono in tempo reale dati dettagliati sul proprio funzionamento, comunicano e distribuiscono tali dati ad altri sistemi informatici in rete. Sono molti gli elementi da proteggere, dai sistemi embedded (sistemi integrati), alle reti di comunicazione, ai sistemi informatici che analizzano e immagazzinano dati (es. cloud).

Ogni volta che si parla dell’imminente rivoluzione dell’industria 4.0 il focus principale si sposta sulla definizione di macchine intelligenti in grado di comunicare tra loro. In effetti, la base dell’evoluzione è l’intelligenza artificiale. Lo sviluppo di questa tecnologia è ancora in corso e non molte persone sono consapevoli del suo ruolo e di come porterà importanti cambiamenti.

Lo scopo di questo lavoro è quello di spiegare l’intelligenza artificiale a livello teorico, analizzando ogni sua sfaccettatura, cercando di capire come mai sta prendendo sempre più piede con il passare del tempo, per essere poi capaci di comprendere come questa tecnologia viene applicata in maniera diversa in vari settori esaminando alcuni casi di studio.

2. INTELLIGENZA ARTIFICIALE

2.1 Definizione

Intelligenza artificiale (AI), non c'è ancora una definizione chiara, precisa ed ampiamente riconosciuta, è quella parte della computer science che può creare un sistema di elaborazione in grado di eseguire compiti come gli esseri umani e anche di imparare dalle proprie attività.

L'intelligenza artificiale è stata ampiamente studiata e resa popolare in una vasta gamma di settori. Negli ultimi anni sono state condotte ricerche significative per incorporare questi principi. Elettronica, telecomunicazioni, informatica, e altre professioni e discipline combinano prontamente informazioni e contenuti intelligenti con la tecnologia AI. Essa può essere usata per imitare la coscienza e il pensiero umano in un'ampia gamma di situazioni. La tecnologia AI crea vantaggi come la capacità di eseguire operazioni di controllo precise, ridurre la dipendenza dall'interazione umana e prevenire efficacemente errori evitabili causati da fattori umani.

Dal punto di vista industriale, le tecnologie di intelligenza artificiale aiutano a percepire l'ambiente circostante ai sistemi e ad analizzare i dati per risolvere i problemi complessi e anche imparare da essi. Lo sviluppo sociale rende la produzione sempre più dipendente dal progresso scientifico e tecnologico, computer, sensori e GPS sono tutti utilizzati nell'intelligenza artificiale. L'utilizzo della tecnologia intelligente nella produzione industriale riduce l'intensità del lavoro dei

dipendenti, aumenta l'efficienza della produzione aziendale e riduce con successo i costi di produzione, rendendo le aziende più competitive sul mercato.

Questa tecnologia, in particolare, può ridurre drasticamente il rischio di lesioni ai lavoratori in ambienti pericolosi così come i costi unitari e il costo del lavoro anche nella produzione.

L'AI crea un modello per la produzione utilizzando un sistema di simulazione che effettua un'analisi approfondita dei dati per adottare le misure precauzionali appropriate in caso di emergenza, garantendo un sistema di produzione regolare, riducendo il rischio di perdita di capitale per le aziende manifatturiere e migliorando notevolmente l'efficienza e la precisione della produzione.

Riducendo al minimo le operazioni manuali, la sicurezza delle attività di produzione viene efficacemente migliorata, così come la precisione nelle operazioni e quindi l'efficienza produttiva e i profitti per l'impresa.

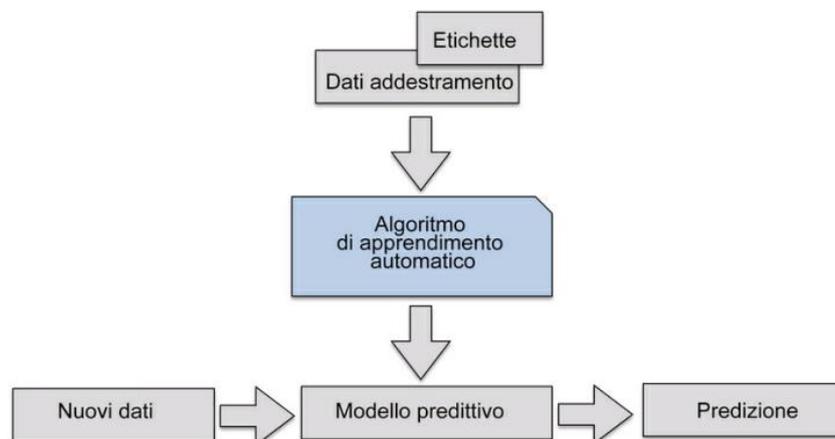
3. MACHINE LEARNING

3.1 Definizione

Il machine learning è la sotto-parte principale dell'intelligenza artificiale a causa della sua enfasi sull'apprendimento e, molte volte, i loro nomi vengono intercambiati. Esso consente di creare programmi in grado di adattarsi a nuove condizioni ed elaborare i dati ottenuti durante il loro funzionamento.

Si basa sullo sviluppo di algoritmi di autoapprendimento che, in una prima fase di "learning", acquisiscono informazioni tramite un'analisi dei dati che hanno a disposizione e, una volta conclusa questa fase, diventano in grado di compiere previsioni sulla base di ciò che hanno imparato.

L'individuazione delle regole e la costruzione di modelli per l'analisi di grandi quantità di dati, che prima richiedeva una presenza umana, viene ora svolta in maniera automatica dal machine learning, fornendo così un'alternativa più efficiente all'assimilazione delle informazioni e migliorando gradualmente le prestazioni dei paradigmi decisionali così definiti.



3.2 Tipi di machine learning

Possono essere individuate principalmente tre macrocategorie di machine learning che si differenziano nelle modalità di apprendimento: supervisionato, non supervisionato e rinforzato.

Nell'apprendimento supervisionato il processo di addestramento si basa solo su dati etichettati. Utilizza cioè dei dati che sono degli esempi con gli input e i relativi output corretti. L'obiettivo è quello di imporre un collegamento tra i dati di input e i relativi dati di output. È detto supervisionato poiché l'intero processo di apprendimento può essere pensato come se fosse seguito da un insegnante o supervisore.

L'apprendimento non supervisionato tratta, invece, dei dati non etichettati o con una struttura ignota, non c'è alcun supervisore in grado di fornire alcun tipo di guida. Questo tipo di algoritmi si adatta ai casi in cui non si possiedono dati già classificati. Trova similitudini e schemi relazionali tra i dati e poi li raggruppa in base alle similarità presenti tra le loro caratteristiche.

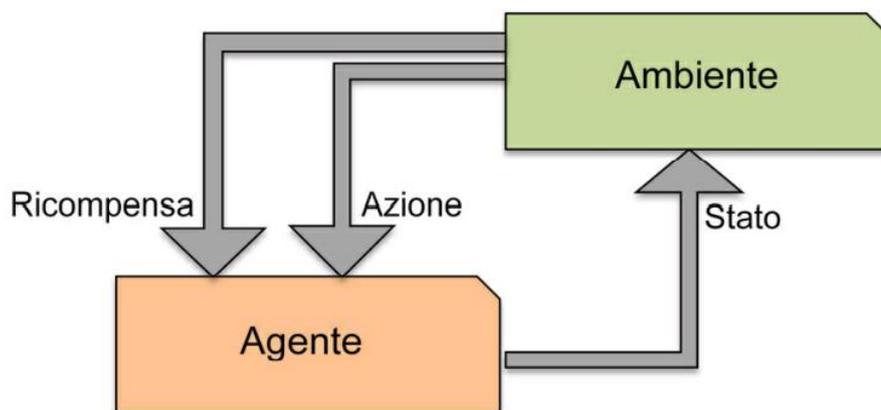
Nella realtà certi algoritmi o metodi non sono né completamente supervisionati né completamente non supervisionati. Generalmente utilizzano una piccola componente di apprendimento supervisionato e una grande componente di apprendimento non supervisionato. Questo tipo di algoritmi viene detto semi supervisionato.

L'apprendimento rinforzato prevede l'utilizzo di metodi diversi dai precedenti e raramente utilizzati. In questo tipo di metodi c'è una sorta di "agente" che viene

allenato per un periodo di tempo in maniera tale che possa agire in uno specifico contesto. L'agente seguirà poi una serie di strategie per interagire con il contesto agendo in base al suo stato corrente. L'apprendimento rinforzato può essere considerato come un esempio di apprendimento con supervisione ma con la differenza che la qualità dell'azione che viene eseguita non viene misurata mediante delle etichette, ma tramite una cosiddetta funzione "ricompensa" (reward). L'agente cerca quindi, mediante un approccio a tentativi trial-and-error, di trovare le azioni che massimizzano questa ricompensa.

3.3 Classificazione

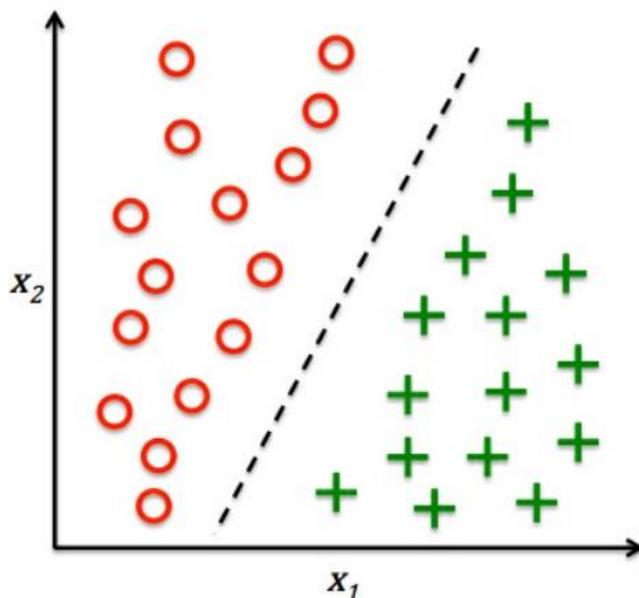
La classificazione è una modalità di apprendimento supervisionato il cui compito è quello di identificare a quale categoria appartiene un dato in input. Ogni nuovo dato di input viene definito istanza e l'obiettivo è quello di prevedere le etichette di categoria di classe per le nuove istanze sulla base delle conoscenze acquisite durante la fase di addestramento.



Un tipico esempio di problema di classificazione binaria è quello del rilevamento dello spam nella posta elettronica. In questo caso le classi sono solo due, l'algoritmo

deve imparare a distinguere se i messaggi di posta elettronica sono spam o non-spam.

In figura vediamo illustrato il concetto di classificazione binaria.



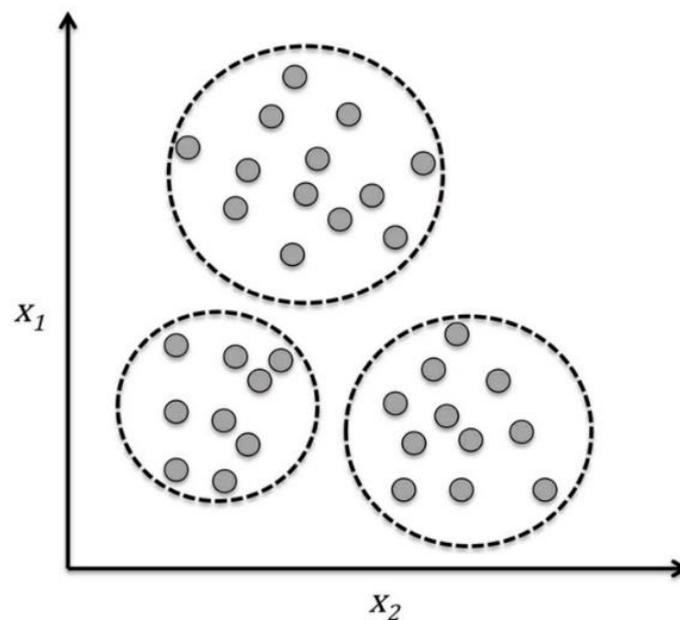
In generale il numero di classi è molto superiore a due, si parla infatti di problemi multi-classe.

3.4 Regressione

La regressione è un altro tipo di apprendimento supervisionato, dove, a differenza della classificazione, si cerca di predire dei valori numerici continui derivati da un certo input. In questa analisi abbiamo diverse variabili descrittive e una variabile target che contiene il risultato, l'obiettivo è quello di imporre una specifica associazione tra i due tipi di variabili.

3.5 Clustering

Il clustering è un'ottima tecnica senza supervisione, viene molto usata poiché capace di trovare similitudini e schemi razionali tra i dati raggruppandoli in gruppi significativi chiamati cluster. Questa tecnica si applica senza avere alcuna conoscenza precedente sull'appartenenza di dati a questi gruppi. Ogni cluster viene definito mediante l'individuazione di un gruppo di dati che condividono una certa similarità.



3.6 Reti neurali

Le reti neurali sono un modello computazionale di machine learning che è stato pensato e poi sviluppato per assomigliare al cervello biologico umano.

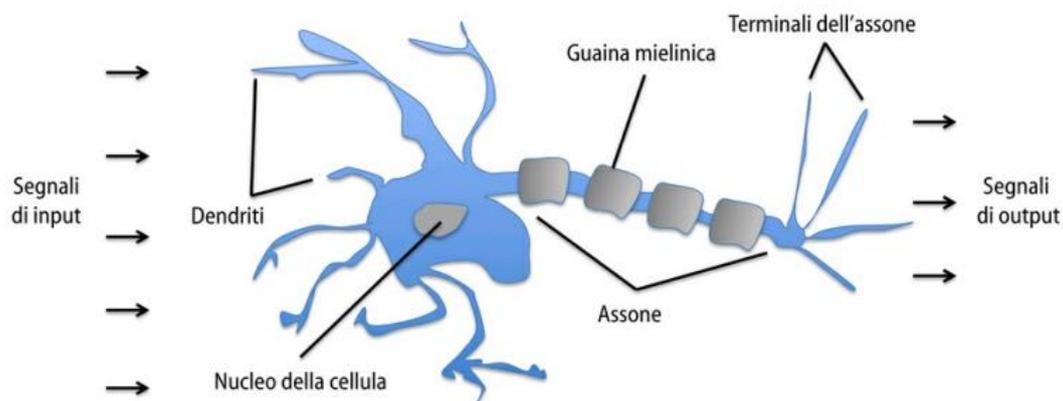
Formate da neuroni artificiali interconnessi, di cui uno strato in grado di acquisire dati in input definito input layer e uno strato di neuroni in uscita detto output layer.

Fra gli strati di input e di output possono essere presenti uno o più strati "nascosti"

(hidden layer) che si occupano della vera e propria elaborazione. Si parla di apprendimento profondo (deep learning) quando gli strati nascosti sono almeno due.

3.6.1 Neurone MCP

I primi a cercare di riprodurre la cellula neurale biologica furono Warren McCullock e Walter Pitts, i quali nel 1943 pubblicarono il primo vero schema di una cellula del cervello umano che prese poi il nome di neurone di McCullock-Pitts MCP.



I neuroni sono cellule del sistema nervoso centrale che si trovano nel cervello e si occupano di elaborare e trasmettere segnali chimici ed elettrici.

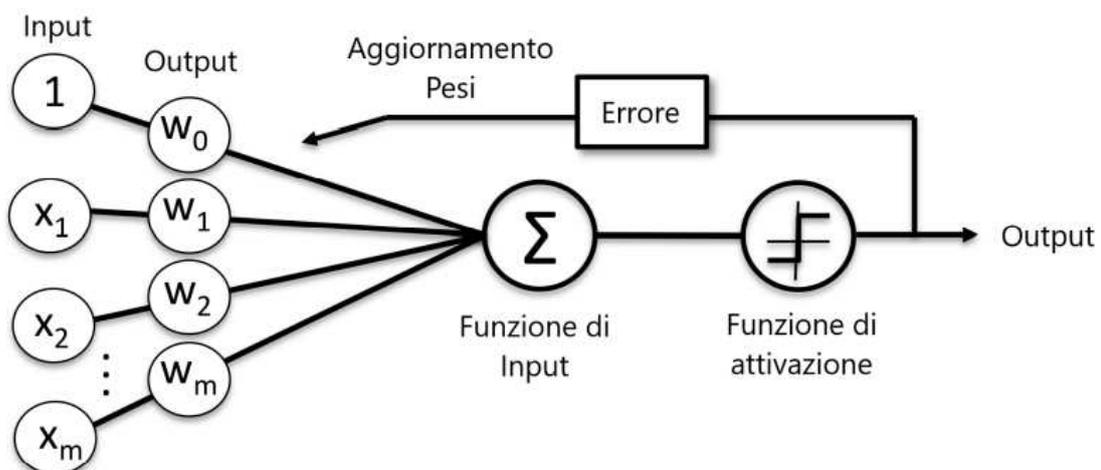
La cellula artificiale ricreata da McCullock e Pitts è una semplice porta logica con output binario, come illustrato in figura, ai dendriti arrivano più segnali, i quali poi passano all'interno della cellula e, se il segnale complessivo che viene accumulato supera una determinata soglia, viene generato un segnale di output che viene poi trasferito all'esterno mediante l'assone.

Il modello MCP presentava diversi limiti, prevedeva solo input e output binari, la soglia di attivazione doveva essere impostata manualmente, tutti gli input venivano

trattati con lo stesso grado di importanza e infine non era in grado di interpretare funzioni che non avessero un comportamento lineare come ad esempio la funzione XOR.

3.6.2 Perceptron

Pochi anni dopo basandosi sul modello MCP Frank Rosenblatt ha pubblicato il primo approccio di regola di apprendimento Perceptron. Con questa regola Rosenblatt ha proposto un algoritmo capace di assegnare un peso diverso ai vari input in modo tale da poter decidere se attivare o meno un determinato neurone. I pesi sinaptici vengono generati in base all'errore presente tra l'output ottenuto e l'output desiderato.



Si parla di perceptron semplici quando utilizzano come funzione di attivazione una semplice funzione a gradino del tipo:

$$\varphi(z) = \begin{cases} 1, & \text{se } z < 0 \\ -1, & \text{altrimenti} \end{cases}$$

dove:

$$z = \sum_{i=0}^{i=m} w_i x_i = \mathbf{w}^T \mathbf{x}$$

Data una rete neurale con N nodi in ingresso e P coppie di addestramento, ciascuna composta da vettore di ingresso \mathbf{x}_p e una risposta desiderata t_p ; fornendo i valori \mathbf{x}_p alla rete neurale se la risposta della rete è uguale alla risposta desiderata i pesi non vengono modificati. Se invece si è verificato un errore i pesi sinaptici vengono modificati in base alla risposta corretta

$$w_i^t = w_i^{t-1} + \Delta w_i^t \quad \text{dove} \quad \Delta w_i = \eta t x_i$$

Con η indichiamo il tasso di apprendimento, può assumere valori nell'intervallo 0-1. È importante notare che la convergenza del Perceptron è garantita solo se le due classi sono separabili linearmente e se il tasso di apprendimento è sufficientemente ridotto. Se le classi non possono essere separate da un confine decisionale lineare, possiamo definire un numero massimo di passi sul dataset di apprendimento e/o una soglia per il numero di errate classificazioni che possiamo tollerare. In caso contrario, il perceptron non smetterebbe mai di correggere i pesi.

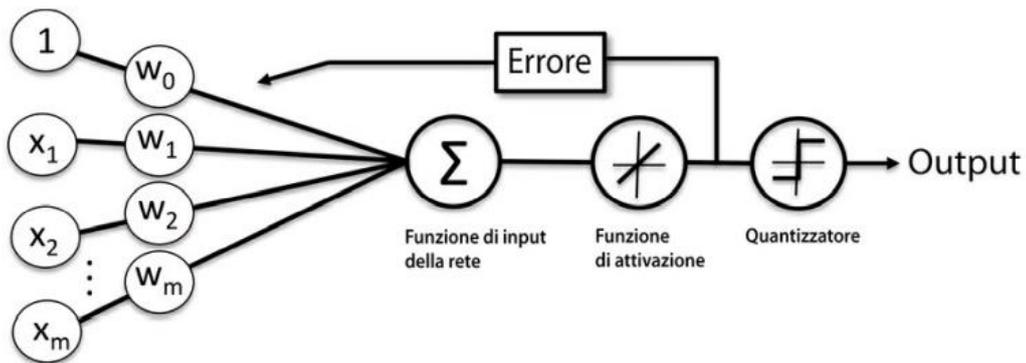
3.6.3 Adaline

Un altro tipo di rete neurale è l'ADaptive LInear NEuron (Adaline). Bernard Widrow e il suo studente di dottorato Tedd Hoff hanno pubblicato questo algoritmo pochi anni dopo il lavoro di Rosenblatt sul Perceptron come miglioramento di quest'ultimo.

L'algoritmo Adaline permette di definire e poi minimizzare le funzioni di costo, cosa che poi risulta particolarmente utile per comprendere meglio algoritmi di classificazione più avanzati che vedremo nei prossimi capitoli come quello delle macchine vettoriali di supporto. La differenza principale tra il Perceptron e Adaline

sta nell'aggiornare i pesi sulla base di una funzione di attivazione lineare piuttosto che tramite la funzione di passo unitario utilizzata dal Perceptron. In Adaline questa funzione di attivazione lineare $\phi(z)$ è semplicemente la funzione identità dell'input della rete tale per cui: $\phi(\mathbf{w}^T \mathbf{x}) = \mathbf{w}^T \mathbf{x}$

Questa funzione di attivazione lineare viene usata per l'apprendimento dei pesi, oltre a questa al posto della funzione di passo unitario vista in precedenza può essere impiegato un quantizzatore in grado di prevedere le etichette delle classi come mostrato in figura.



3.6.4 Discesa del gradiente

L'utilizzo di funzioni di attivazione lineari permette la descrizione delle prestazioni della rete attraverso una funzione continua e differenziabile J che misura l'errore della rete. Possiamo immaginare questa funzione come una funzione di costo da voler minimizzare. La funzione di costo J viene definita come la somma dei quadrati degli errori di previsione commessi dalla rete:

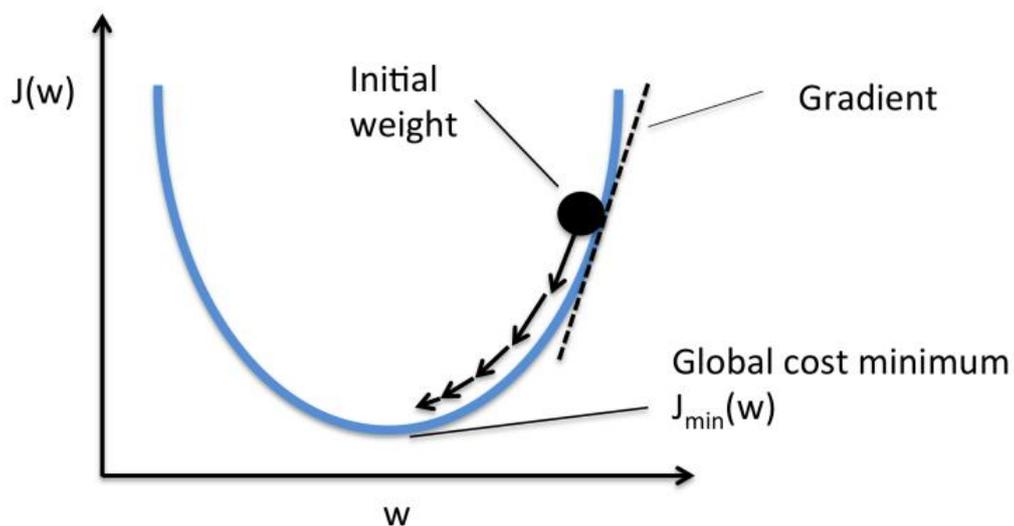
$$J(\mathbf{w}) = \frac{1}{2} \sum_i (y^{(i)} - \phi(z^{(i)}))^2$$

La funzione di costo come possibile vedere dall'equazione dipende unicamente dal valore delle connessioni sinaptiche. Infatti, il gradiente è individuato da un'equazione dalle derivate parziali di J rispetto a ciascun peso sinaptico w_j . L'obiettivo è minimizzare l'errore pertanto è opportuno modificare i pesi sinaptici nella direzione opposta del gradiente di J .

$$w = w + \Delta w \quad \text{dove} \quad \Delta w = -\eta \nabla J(w)$$

$$\frac{\partial J}{\partial w_j} = \sum_i (y^{(i)} - \phi(z^{(i)})) x_j^{(i)}$$

Il tasso di apprendimento *eta* controlla il movimento sulla superficie dell'errore: se *eta* è troppo grande si rischia di balzare da una parete all'altra senza raggiungere il minimo. Al contrario se *eta* fosse troppo piccolo la discesa potrebbe risultare estremamente lenta.



3.6.5 Discesa stocastica del gradiente

L'esecuzione dell'algoritmo a discesa del gradiente batch può essere piuttosto costosa dal punto di vista computazionale, per il fatto che tale situazione costringe a rivalutare l'intero dataset di addestramento ogni volta che compiamo un passo verso il minimo globale. Un'alternativa comune all'algoritmo a discesa del gradiente batch è quello di discesa del gradiente stocastica, chiamata anche discesa del gradiente iterativa o online. Invece di aggiornare i pesi sulla base della somma degli errori accumulati rispetto ai campioni, aggiorniamo i pesi in modo incrementale per ogni campione di addestramento. Sebbene la discesa del gradiente stocastica possa essere considerata un'approssimazione della discesa del gradiente, in genere raggiunge la convergenza molto più velocemente, poiché i pesi vengono aggiornati più frequentemente. Poiché ciascun gradiente viene calcolato sulla base di un singolo esempio di addestramento, la superficie di errore è più rumorosa rispetto alla discesa del gradiente, il che significa anche avere il vantaggio che la discesa del gradiente stocastica è in grado di sfuggire con maggiore facilità agli avvallamenti rappresentati dai minimi locali. Per ottenere risultati accurati tramite la discesa del gradiente stocastica, è importante presentarle i dati nel modo più casuale possibile per impedire l'innescare di cicli.

Un compromesso fra discesa del gradiente batch e discesa del gradiente stocastica è il cosiddetto apprendimento mini-batch. L'apprendimento mini-batch può essere compreso come l'applicazione di una discesa del gradiente batch al piccolo sottoinsieme dei dati di addestramento, per esempio 50 campioni alla volta. Il vantaggio rispetto alla discesa del gradiente batch è il fatto che la convergenza viene

raggiunta più velocemente tramite i mini-batch, a causa dell'aggiornamento più frequente dei pesi addestramento.

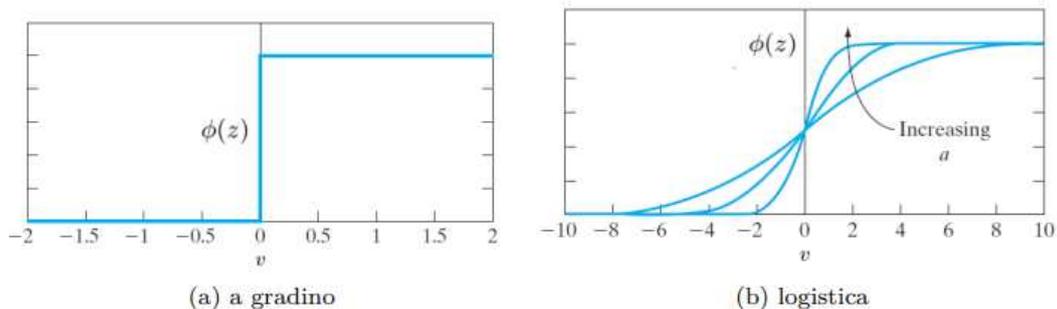
3.6.6 Funzione di attivazione sigmoide

La funzione sigmoide, il cui grafico è a forma di "S", è di gran lunga la forma più comune di funzione di attivazione utilizzata nella costruzione di reti neurali. È definita come una funzione strettamente crescente che mostra un comportamento bilanciato tra lineare e non lineare. Un esempio della funzione sigmoide è la funzione logistica definita dall'equazione:

$$\phi(z) = \frac{1}{1 + \exp^{-az}}$$

dove a è il parametro di pendenza.

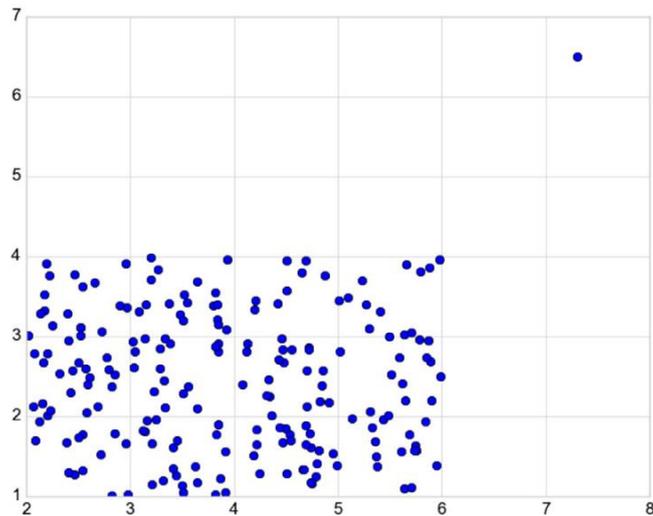
Variando il parametro di pendenza si possono ottenere funzioni sigmoidi di diversa pendenza come illustrato in figura.



La funzione sigmoide assume un intervallo continuo di valori nell'intervallo 0-1, tale output può essere interpretato come la probabilità che uno specifico campione appartenga ad una determinata classe. È importante far notare che la funzione sigmoide a differenza della funzione a gradino è differenziabile e perciò è possibile utilizzare un algoritmo di ottimizzazione come quello della discesa del gradiente.

3.7 Anomaly detection

Cos'è l'anomaly detection? Per fornire una risposta a questa domanda, osserviamo la figura che mostra un set di dati 2D:



Senza il bisogno di dare un'occhiata più da vicino all'immagine, un punto cattura la nostra attenzione: il punto situato in (7.3, 6.5), è distaccato dagli altri. La prima cosa che viene in mente quando si vede questa immagine è "Questo punto dati è davvero diverso dagli altri, non è normale. Ci deve essere un errore da qualche parte, non dovrebbe essere lì". Quel punto è chiamato valore anomalo.

Più formalmente, un valore anomalo può essere definito come un'osservazione che si discosta così tanto dalle altre osservazioni da destare sospetti che sia stato generato da un meccanismo diverso. I valori anomali sono anche chiamati valori anormali, irregolarità o anomalie, in contrasto con valori normali o regolarità che sembrano seguire la stessa distribuzione. Il rilevamento dei valori anomali è l'incarico che mira a scoprire automaticamente quei punti dati devianti. Le sue applicazioni sono numerose:

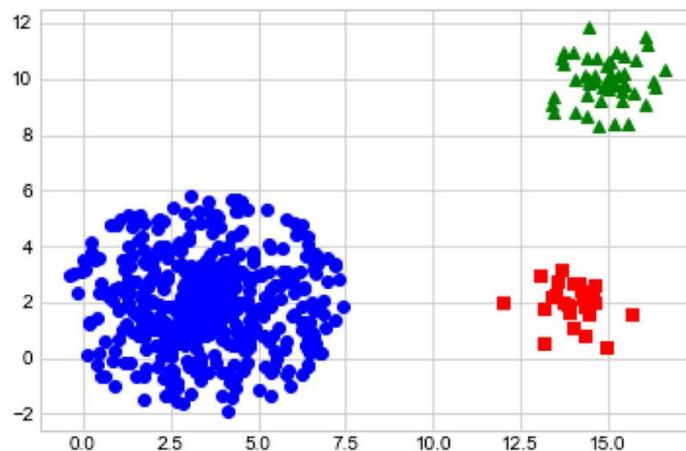
- nelle architetture High Performance Computing (HPC), o più in generale nei sistemi di ingegneria, i sensori vengono utilizzati per raccogliere informazioni sui diversi componenti del sistema. L'analisi delle registrazioni di questi sensori, di solito in tempo reale, può aiutare a identificare i comportamenti difettosi di alcuni componenti e correggerli in seguito. Ad esempio, una temperatura molto alta di una componente potrebbe indicare che il sistema di raffreddamento non funziona correttamente;
- in medicina, le fotografie MRI possono essere elaborate per identificare le cellule cancerose;

La nozione di anomalia può essere ambigua e fortemente dipendente dal contesto, tanto più che anche la nozione di regolarità può essere ambigua. Ad esempio, negli HPC ci possono essere momenti in cui il sistema è sottoposto a forti sollecitazioni (che chiameremo -1-). La CPU lavorerà di più durante quei periodi e ciò causerà un aumento della sua temperatura, rispetto ai momenti in cui non viene utilizzata molto (chiamati -0-). In aggiunta a ciò, possiamo avere momenti (-2-) durante i quali la temperatura della CPU è superiore o vicina alla temperatura che abbiamo durante i momenti di forte richiesta, nonostante il sistema non sia sottoposto a un grande sforzo, indicando che c'è davvero qualcosa che non va nel sistema di raffreddamento. Senza conoscenze pregresse sul sistema (da sapere che a volte la temperatura può essere elevata perché la CPU è davvero tanto richiesta), si può considerare che le temperature raccolte durante -1- sono anormali, soprattutto quando questi periodi sono pochi in confronto con -0-. Quelle temperature in -1- sarebbero quindi segnalate come anomale (come quelle in -2-, ovviamente). D'altra parte, invece, si può

considerare che solo la situazione -2- è anormale, ma ciò richiede di sapere che la situazione -1- può verificarsi e non è correlato a un difetto del sistema. In questo caso le temperature in -1- sono valori anomali e le temperature in -2- sono anomalie.

Tuttavia, poiché questa distinzione richiede una certa conoscenza del sistema (il contesto), in genere in letteratura entrambi sono indicati e classificati come anomalie, e le osservazioni in -2- sono dette anomalie contestuali nei casi più stringenti.

La prossima figura illustra anche un esempio di ambiguità quando si tratta di anomalie.



Ci sono 500 punti dati rotondi, 50 triangoli e 25 quadrati. L'intero gruppo di triangoli e l'intero gruppo di quadrati sono anomalie? Sono anomalie solo i punti che non sono davvero vicino ai centri dei grappoli di triangoli o quadrati? Potrebbero essere necessarie ulteriori conoscenze per fornire risposte a queste domande con certezza e come esseri umani possiamo avere accesso a questa conoscenza analizzando i punti dati ambigui o semplicemente tracciando il set di dati come nelle due figure (che non risulta abbastanza nel secondo caso). Ma la macchina non ha sempre tutte queste conoscenze. Inoltre, in questi esempi abbiamo set di dati bidimensionali facili da

visualizzare. Difficili sono i casi di situazioni reali in cui i set di dati possono avere centinaia di dimensioni. Di conseguenza, non potremmo nemmeno essere in grado di fornire le conoscenze aggiuntive necessarie. Un algoritmo di rilevamento delle anomalie dice solo per ogni dato se è anormale o meno, a volte con un punteggio che indica il grado in cui pensa che il dato sia anomalo, e questo è tutto. Anche gli informatici, nella maggior parte dei casi, non sono in grado di spiegare perché l'algoritmo ha individuato un dato specifico come insolito rispetto ad altri. Non esiste in letteratura una tassonomia unificata dei metodi di rilevamento delle anomalie. Ad un basso livello di granularità, una distinzione può essere effettuata tra algoritmi basati sull'etichettatura del set di dati. I metodi di rilevamento delle anomalie supervisionati utilizzano un set di dati etichettato durante l'addestramento, e l'identificazione delle anomalie è quindi un'attività di classificazione binaria in cui vi è un elevato squilibrio nel set di dati, poiché le anomalie sono poche rispetto ai dati regolari. Quando le etichette sono assenti, il rilevamento delle anomalie viene eseguito senza supervisione: non c'è addestramento, i dati vengono solo inviati all'algoritmo che identifica i valori anomali. Quest'ultimo è più conveniente poiché etichettare un set di dati è un compito arduo e può essere difficile avere accesso a dati già etichettati. Inoltre, tutte le anomalie potrebbero non essere note prima di costruire l'algoritmo: nuove anomalie diverse da tutte le precedenti possono apparire e dovrebbero essere correttamente identificate. Tra le impostazioni supervisionate e non supervisionate, gli autori a volte aggiungono nelle loro recensioni l'opzione semi-supervisionata in cui vengono utilizzate solo istanze regolari durante la formazione. In tal caso, un modello delle istanze normali viene appreso e le anomalie sono le istanze che non si adattano al modello. Ma poiché i valori anomali sono

pochi nel set di dati e al giorno d'oggi la maggior parte di questi metodi sono sufficientemente robusti da fornire buoni risultati anche con la presenza di valori anomali nel training set, classificheremo loro nei metodi non supervisionati. In definitiva, ciò che includeremo nell'insieme dei metodi di rilevamento delle anomalie senza supervisione in questo lavoro sono quelli che non richiedono formazione (perché sono completamente non supervisionati) e quelli che richiedono formazione, ma sufficientemente robusti da non essere disturbati dalla presenza di anomalie nel training set. L'impostazione senza supervisione è la più realistica quando si tratta di rilevamento di anomalie per i motivi che abbiamo menzionato in precedenza, ci concentreremo quindi su di essa. Non esiste nemmeno una tassonomia unificata per il rilevamento di anomalie senza supervisione. Alcuni autori, per esempio, fanno una distinzione tra metodi basati sul nearest-neighbor, clustering, statistici, subspace e classifier; mentre altri considerano tre insiemi di metodi: basati sulla densità, basati sulla distanza e basati su modelli. Probabilmente i metodi basati sul nearest-neighbor, basati sulla distanza e basati sulla densità possono essere messi insieme, poiché le distanze sono calcolate per valutare le densità e tutti si basano sui calcoli delle distanze. I metodi basati sul clustering non appartengono al gruppo precedente, perché la nozione di cluster è in contrasto con i metodi precedenti, anche se le distanze tra i punti dati sono calcolate. I metodi basati su modelli dovrebbe essere una categoria distinta per raggruppare metodi semi-supervisionati robusti e metodi per i quali viene appreso un modello dei punti dati. I metodi basati sul clustering appartengono a questa categoria, poiché il clustering è un modello del set di dati. Aggiungiamo ai due gruppi precedenti i metodi basati su reti neurali contenenti tutti gli algoritmi di rilevamento delle anomalie di deep learning.

Fondamentalmente, proponiamo di dividere i metodi di rilevamento delle anomalie in tre gruppi: metodi basati sulla distanza, metodi basati su modelli e metodi basati su reti neurali. Come accennato, il presente lavoro non intende fornire una rassegna esaustiva degli algoritmi esistenti. Il focus sarà su quelli più promettenti/usati di ogni categoria.

3.7.1 Metodi basati su distanza

In questa categoria rientrano tutti i metodi che si basano sul calcolo della distanza per identificare le anomalie. Questo calcolo della distanza può essere utilizzato, ad esempio, per calcolare la densità e contrassegnare come punti dati anomali quelli che si trovano in regioni a bassa densità.

Il Local Outlier Factor (LOF) confronta la densità di un punto dati con la densità dei suoi k vicini più prossimi, con l'ipotesi che per un "inlier" queste due quantità saranno approssimativamente uguali. La densità di un punto dati x in questo contesto è l'inverso della media della distanza massima tra x e il suo vicino e la distanza da quel vicino al suo vicino più lontano. Questo trattamento locale è efficace negli scenari in cui sono presenti cluster di diversa densità il set di dati: anche per i cluster sparsi i punti dati che si trovano in profondità all'interno del cluster avranno all'incirca la stessa densità dei loro vicini più vicini. Di conseguenza, il loro LOF sarà vicino a 1. Il LOF di un punto dati x è dato da

$$LOF_k(x) = \frac{\sum_{y \in N_k(x)} \frac{l_k(y)}{l_k(x)}}{|N_k(x)|}$$

Dove $N_k(x)$ è l'insieme dei k vicini più prossimi di x e $l_k(x)$ è la densità di raggiungibilità locale di x definita da:

$$l_k(x) = \frac{|N_k(x)|}{\sum_{y \in N_k(x)} \max(d(y, k), d_k(y))}$$

Nella seconda equazione, $d_k(x)$ è la distanza D tale che vi siano almeno k punti dati y per i quali $d(y, x) \leq D$ e vi siano al massimo $k - 1$ punti dati z per i quali $d(z, x) < D$. In altre parole, è la distanza tra x e il suo k° vicino più prossimo.

Il LOF di un valore anomalo non ha un intervallo specifico di valori, ma è delimitato.

L'incidenza di k sui LOF dei punti dati non è chiara. Aumentare (o diminuire) il valore di k non sempre aumenta (o diminuisce) i valori del LOF.

Un altro metodo per determinare un intervallo per i valori di k è tramite il limite inferiore di k , anche se il valore potrebbe dipendere dall'applicazione, scegliere da 10 a 20 funziona bene in generale. Infine, si suggerisce di calcolare i LOF dei punti dati per i diversi valori di k nel range trovato e prendere aggregati come il massimo, il minimo o la media per trovare i valori finali dei LOF. Tuttavia, prendere il minimo può cancellare completamente la natura periferica di un punto dati e prendere la media può diluire la natura periferica di un punto dati, ed è per questo che spesso si usa il valore massimo negli esperimenti.

Poiché il LOF utilizza la distanza euclidea per selezionare i vicini più vicini di un punto dati, la sua stima della densità può essere errata quando le caratteristiche hanno una correlazione lineare.

Per risolvere questo problema, è stato introdotto il fattore anomalo basato sulla connettività (Connectivity-based Outlier Factor: COF). Il COF utilizza la distanza di concatenamento invece della distanza euclidea e si comporta in modo simile al LOF per il calcolo dei punteggi anomali.

3.7.2 Metodi basati su modelli

L'idea alla base dei metodi di clustering per il rilevamento delle anomalie è raggruppare il set di dati e quindi contrassegnare come anomalie i punti dati che non appartengono a nessun cluster. A tal fine, in un ambiente non supervisionato, il metodo di clustering deve essere sufficientemente robusto da non essere sensibile alla presenza di valori anomali nel set di dati: i metodi sensibili cercheranno il più possibile di inserire i valori anomali in cluster, il che può portare tali istanze a essere contrassegnate come istanze normali o semplicemente ad eliminare questi valori anomali. Metodi robusti, non forzano i valori anomali nei cluster. Un evidente svantaggio di questa concezione è che se ci sono gruppi di anomalie nel set di dati saranno considerati come istanze regolari. Questo problema può essere risolto mediante una post-ispezione dei cluster: i cluster densi di grandi dimensioni sono considerati normali e i cluster sparsi o piccoli sono considerati anomali.

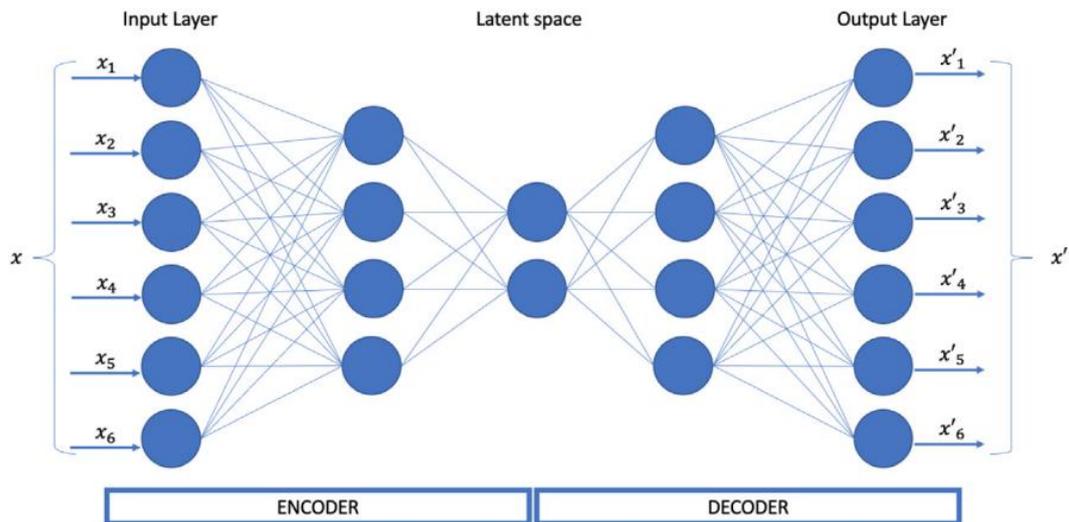
Dopo aver proiettato i dati in uno spazio dimensionale superiore utilizzando un One-Class Support Vector Machines (One-Class SVM), esso prova a tracciare un confine attorno alle istanze di dati risolvendo un problema di ottimizzazione. Una funzione di decisione viene quindi estratta da questo confine. Il valore della funzione sarà +1 per i punti dati all'interno della regione delimitata dal confine e -1 per gli altri. Da questa descrizione, è ovvio che i One-Class SVM sono un metodo di rilevamento anomalo semi-supervisionato, poiché viene appreso un modello dei punti normali. Ma poiché i One-Class SVM sono abbastanza robusti da poter gestire la presenza di anomalie nei dati di addestramento, sono considerati non supervisionati.

Per i One-Class SVM robusti, le variabili di slack già presenti nel classico obiettivo di ottimizzazione degli One-Class SVM vengono modificate per tenere conto dei valori anomali. Per η One-Class SVM, esiste un meccanismo di soppressione dei valori anomali attraverso una variabile η che rappresenta la normalità di un punto dati. Per entrambi i metodi, viene calcolato un punteggio anomalo basato sulla distanza del punto dati dal limite di decisione. I punti dati normali hanno un punteggio compreso tra 0 e 1 e, più un punto dati è esterno, maggiore è il suo punteggio.

3.7.3 Metodi basati su reti neurali

Uno dei primi lavori sul rilevamento dei valori anomali con il deep learning è [9]. In quest'ultimo, gli autori utilizzano una rete neurale replicatrice (RNN) con tre livelli nascosti per eseguire il rilevamento dei valori anomali. Anche gli AutoEncoder (AE), che sono stati precedentemente utilizzati per la riduzione della dimensionalità e hanno una struttura simile agli RNN, vengono sfruttati per il rilevamento dei valori anomali. Proprio come una rete neurale replicatrice, l'autoencoder riceve come input un punto dati e cerca di ricostruirlo. Innanzitutto, un insieme di livelli chiamato codificatore trasforma l'input in un altro punto dati con meno caratteristiche nello spazio noto come spazio latente. Successivamente, un altro insieme di livelli chiamato decodificatore tenta di trasformare i dati dimensionali inferiori nell'input originale. Durante l'addestramento, la rete neurale cercherà di minimizzare l'errore di ricostruzione che è la differenza tra l'output x' e l'input x . Con un autoencoder perfetto l'output è sempre il punto dati originale ($x' = x$), e l'errore di ricostruzione è quindi zero. Per ottenere i punti dati dimensionali inferiori dobbiamo solo ottenere i

punti dati corrispondenti nello spazio latente (dopo la fase di codifica). La figura mostra un esempio di autoencoder:

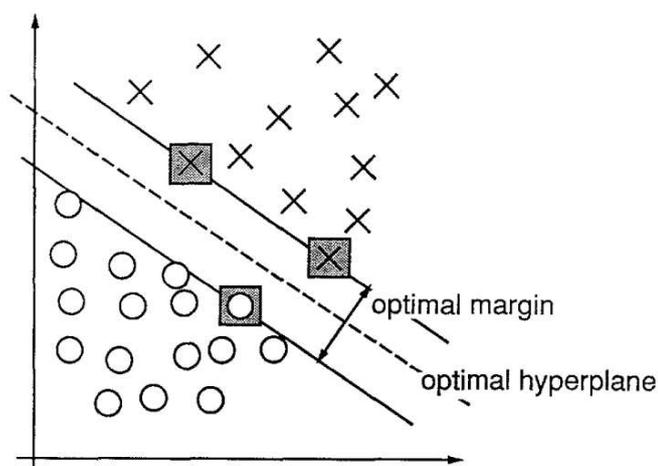


L'utilizzo di codificatori automatici per il rilevamento dei valori anomali presuppone che i valori anomali avranno sempre un errore di ricostruzione più elevato rispetto ai normali punti dati e questo errore di ricostruzione costituisce quindi una misura di valori anomali. Questa ipotesi è giustificata dal fatto che l'auto encoder apprende un modello di normalità: dovrebbe essere in grado di ricostruire perfettamente le istanze regolari e gli outlier che deviano dai punti dati regolari dovrebbero essere ricostruiti male. In teoria, un codificatore automatico è un metodo di rilevamento delle anomalie semi-supervisionato in addestrato solo con istanze regolari in modo che i valori anomali possano essere facilmente rilevati con il loro elevato errore di ricostruzione in un secondo momento. Tuttavia, con architetture più robuste che tengono conto della presenza di valori anomali nei dati di addestramento, i codificatori automatici possono essere classificati negli approcci non supervisionati per il rilevamento delle anomalie.

Gli autoencoder non sono gli unici algoritmi di riduzione della dimensione utilizzati per il rilevamento di valori anomali, ma l'argomento del rilevamento di anomalie mediante reti neurali profonde è molto ampio e coprirlo interamente va oltre lo scopo di questo lavoro.

3.8 Support Vector Machine SVM

La rete di vettori di supporto è un metodo di apprendimento per problemi di classificazione a due gruppi. Il metodo implementa concettualmente la seguente idea: i vettori di input sono mappati in modo non lineare su uno spazio di caratteristiche di dimensioni molto elevate. In questo spazio di caratteristiche viene costruita una superficie decisionale lineare. Le proprietà speciali della superficie decisionale assicurano un'elevata capacità di generalizzazione della macchina di apprendimento. L'idea alla base della rete di vettori di supporto è stata precedentemente implementata per il caso ristretto in cui i dati di addestramento possono essere separati senza errori.



L'immagine mostra un esempio di un problema separabile in uno spazio bidimensionale. I vettori di supporto, contrassegnati da quadrati grigi, definiscono il margine di massima separazione tra le due classi. Date due classi e un insieme di esempi già etichettati, un algoritmo di addestramento per le SVM costruisce un modello capace di assegnare i nuovi dati a una delle due classi.

La rete di vettori di supporto combina tre idee: la tecnica di soluzione da iperpiani ottimi (che consente un'espansione del vettore soluzione su vettori di supporto), l'idea di convoluzione del prodotto scalare (che estende le superfici della soluzione da lineare a non lineare) e la nozione di margini morbidi (per consentire errori sul training set).

L'SVM è stato testato e confrontato con le prestazioni di altri algoritmi classici. Nonostante la semplicità del design nella sua superficie decisionale, esso mostra prestazioni molto buone nello studio comparativo. Altre caratteristiche come il controllo della capacità e la facilità di modifica della superficie decisionale implementata rendono la rete dei vettori di supporto una macchina di apprendimento estremamente potente e universale.

4. APPLICAZIONI

4.1 Un supporto decisionale alla gestione delle modifiche ingegneristiche nell'industria automobilistica

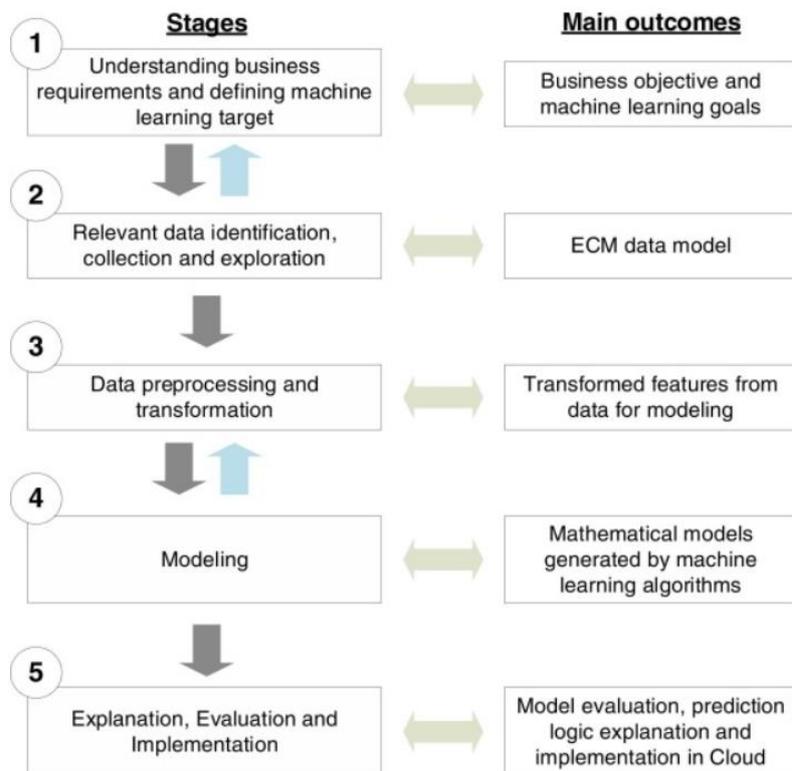
4.1.1 Caso di studio

Come parte essenziale del ciclo di vita del prodotto (PLC), il time-to-market dei prodotti è influenzato dai processi di Engineering Change Management (ECM). Una modifica ingegneristica (EC) fa parte di un processo formale nell'industria per descrivere, razionalizzare, determinare, rilasciare componenti per la produzione finale o apportare modifiche a progetti già rilasciati. Include informazioni su forma, funzionalità, luogo di produzione, costo e altri dati rilevanti. Il tempo intercorso dalla creazione all'approvazione di una richiesta di modifica può richiedere settimane o addirittura mesi, senza apparenti ragioni. Inoltre, le modifiche a un componente possono portare a reazioni a catena impreviste ad altri componenti. Pertanto, l'identificazione degli impatti delle modifiche è una sfida per tutti i produttori di apparecchiature originali (OEM). Per affrontare le sfide di cui sopra, gli autori Yuwei Pan e Rainer Stark, in: "An interpretable machine learning approach for engineering change management decision support in automotive industry" [12] hanno sviluppato e creato una soluzione di supporto decisionale basata sull'apprendimento automatico. Diversi algoritmi sono stati applicati per creare modelli più robusti. Gli impatti e i tempi di consegna delle richieste di modifica ingegneristica (ECR) sono previsti e spiegati dalle Local Interpretable Model-agnostic Explanations (LIME). È stato condotto un caso di studio sui dati del mondo reale di un'azienda automobilistica. Dopo la valutazione con esperti del settore, è

stato dimostrato che l'approccio alla soluzione apporta contributi positivi all'aumento della qualità, dell'efficienza e della trasparenza dei processi ECM esistenti.

4.1.2 Soluzione proposta

Cross-Industry Standard Process for Data Mining (CRISP-DM) è un processo ampiamente utilizzato per orientare i ricercatori per un progetto di data science standard. Implica passaggi dalle esigenze aziendali fino alla distribuzione, che indica come l'interattività all'interno del processo. CRISP-DM comprende sei fasi: comprensione aziendale, comprensione dei dati, preparazione dei dati, modellazione, valutazione e distribuzione. La sequenza di ogni fase non è rigida. Le interazioni tra le diverse fasi sono sempre necessarie e un progetto non termina una volta distribuita la soluzione.



4.1.3 Algoritmo Random Forest

Il Random Forest è un approccio di classificazione che consiste di centinaia o migliaia di alberi decisionali non correlati. Due tipi di casualità sono usati per governare la crescita di ogni albero. Il primo è il bagging, per far crescere ogni albero viene utilizzato solo un sottoinsieme casuale di dati di addestramento scelti con la sostituzione. Il secondo è quello di selezionare casualmente un sottoinsieme di funzionalità in ciascun nodo, e quello dei due che offre la migliore divisione viene utilizzato per dividere il nodo in modo iterativo. Per ogni istanza di dati non visualizzati, ogni albero decisionale genera una previsione dell'etichetta. L'etichetta con il maggior numero di voti è la previsione finale dell'algoritmo.

Dopo aver valutato le soluzioni ECM all'avanguardia e le metodologie di apprendimento automatico e averle combinate con le attuali sfide del settore, gli autori hanno riconosciuto il potenziale dell'applicazione di metodi di apprendimento automatico nelle attività di ingegneria. Nel settore è necessaria una soluzione di supporto decisionale ECM in grado di apprendere automaticamente dai dati storici, fornendo suggerimenti affidabili ed essere adattata a diverse classi di prodotti.

Il Random Forest è stato utilizzato come classificatore di base nella soluzione proposta grazie alla sua efficienza e alle buone prestazioni per le caratteristiche sparse ad alta dimensione.

4.2 Modelli di valutazione della sicurezza antincendio per l'industria del carbone

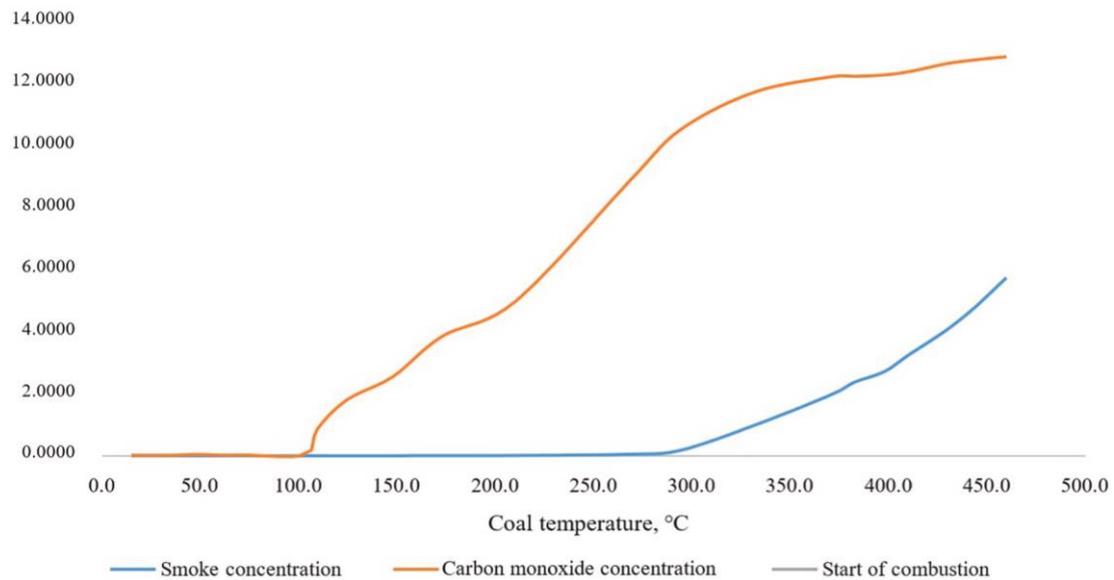
4.2.1 Caso di studio

Uno dei principali problemi dell'industria carboniera è l'auto-ossidazione del carbone, che porta a incendi e disastri indotti dall'uomo. S. Sun, D. Gura e B. Dong nel loro lavoro [13] hanno cercato di utilizzare tecniche di apprendimento automatico e l'algoritmo più efficace per prevenire gli incendi nelle miniere. Due tecniche di apprendimento automatico, il classificatore Naive Bayes e le Macchine di Supporto Vettoriali (SVM), sono state impiegate per raggiungere l'obiettivo. L'algoritmo è stato sviluppato sulla base della dipendenza della quantità di gas dalla temperatura del carbone.

È stato scoperto che prima della comparsa di un fuoco aperto, c'erano altri due intervalli di temperatura senza combustione, dimostrando una chiara dipendenza delle concentrazioni di fumo e monossido di carbonio dalla temperatura del carbone. Questa tecnica è eccellente per prevedere la prima fase della combustione che è confermata dai valori dei parametri corrispondenti. I risultati hanno dimostrato che la metodologia era eccellente negli studi di laboratorio. L'algoritmo proposto da S. Sun et al. [13] può essere utilizzato come nuovo metodo per prevedere gli incendi nelle miniere di carbone ed elaborare una branca dell'apprendimento automatico per stabilire modi più efficaci per rilevare la combustione nelle sue fasi iniziali.

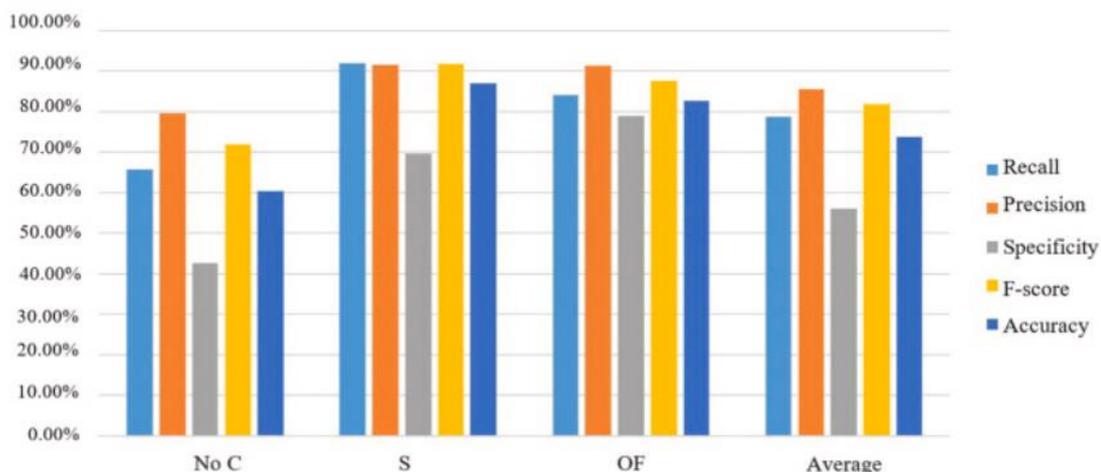
4.2.2 Trattamento dei dati ottenuti tramite classificatore Naive Bayes

La figura mostra le curve di dipendenza delle concentrazioni di fumo e monossido di carbonio nell'aria rispetto alla temperatura del carbone.



Un forte aumento di CO si verifica dopo 25 minuti di fornitura d'aria. Un rapido aumento della concentrazione di fumo nell'aria è stato osservato al 40° minuto dell'esperimento ed è ulteriormente aumentato dopo 20 minuti dall'inizio dell'emissione.

Come mostrato nella figura, un aumento significativo della quantità di CO inizia quando il carbone raggiunge la temperatura di 107°C. Un aumento significativo delle emissioni di fumo si è verificato quando il carbone è stato riscaldato a 294°C.

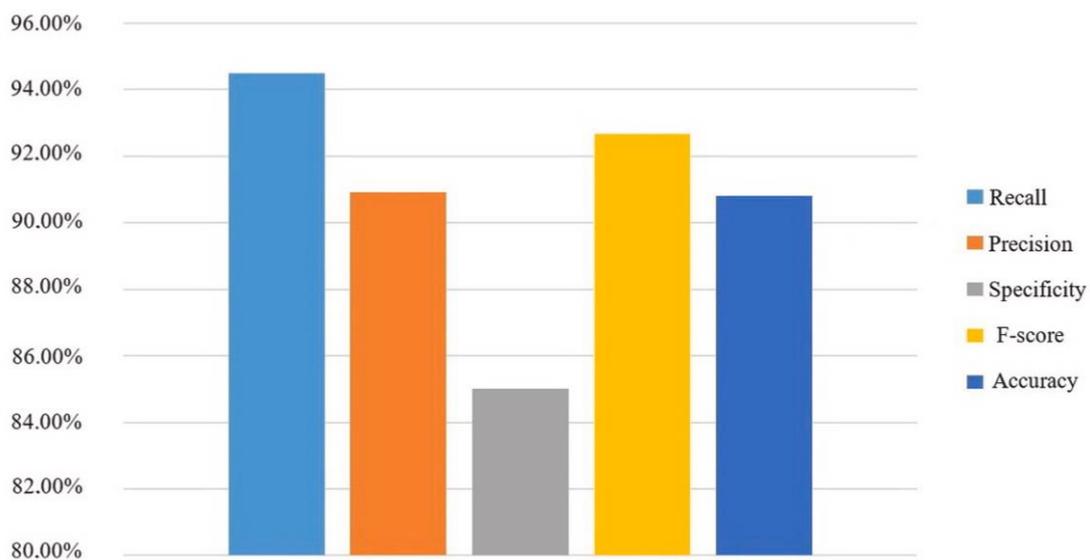


La figura mostra che i valori di richiamo sono compresi tra 65,63% e 91,93%, con una media del 78,78%. I valori di precisione sono compresi tra 79,55% e 91,36%, con una media dell'85,45%. I valori di specificità vanno dal 42,552% al 78,95%, con una media del 56,06%. I valori del punteggio F sono compresi tra 71,92% e 91,64%, con una media dell'81,78% e l'accuratezza complessiva (precisione) dell'algoritmo varia tra il 60,39% e l'86,96%, con una media del 73,67%. In caso di sfocatura, i più alti sono i valori di richiamo, f-score e precisione. I valori di precisione sono quasi gli stessi quando si rileva fuoco fumante e aperto. Allo stesso tempo, la specificità è leggermente superiore per la previsione del fuoco aperto. Tutti i parametri della matrice di disallineamento erano i più bassi.

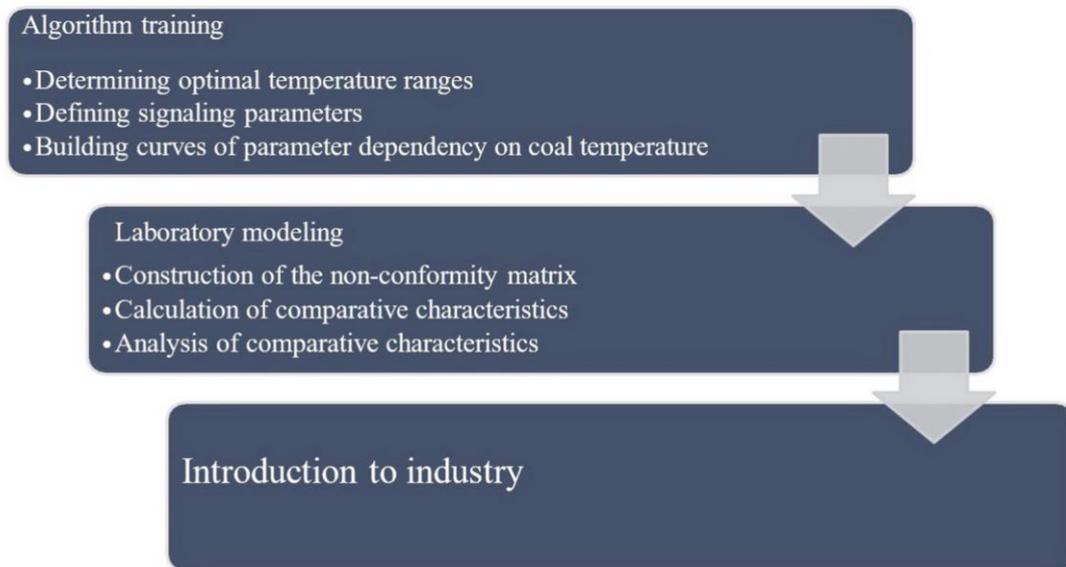
Questo modello è ben adattato per rilevare il fumo e il fuoco aperto, poiché la precisione dell'algoritmo è molto elevata in questo caso. Non è consigliabile utilizzare NBC per determinare l'assenza di combustione, poiché vi è un'alta percentuale di letture errate e piccoli valori di tutte le caratteristiche.

4.2.3 Trattamento dei dati ottenuti con il metodo SVM

L'istogramma seguente mostra che l'efficienza di SVM per l'intervallo di temperatura fino a 107 °C è molto elevata rispetto all'NBC. Pertanto, il valore di richiamo è 94,49%, la precisione è 90,91%, la specificità è 85%, il punteggio finale è 92,66% e l'accuratezza dell' algoritmo comprende il 90,82%. Questi indicatori sono molto più alti di quelli della NBC.



Quindi, un algoritmo composto da due tecniche (SVM e NBC) dovrebbe essere utilizzato come il più efficace. In questo studio, l'SVM funziona a temperature di 20°C-107°C, cioè nell'intervallo in cui non avviene combustione. Se la temperatura tende ad aumentare, il programma cambia in NBC e analizza la situazione. Inoltre, avvisa all'inizio della combustione senza fiamma e sull'ulteriore aumento della temperatura durante il fuoco aperto. In generale, il meccanismo di funzionamento di questi algoritmi è illustrato nella prossima figura.



I risultati di un NBC modificato per la previsione di nessuna combustione sono significativamente inferiori a quelli ottenuti da Shu et al. [16].

4.2.4 Conclusioni

È stato stabilito che i metodi esistenti per prevedere l'accensione del carbone hanno dei limiti, per cui non possono essere utilizzati per un'ampia applicazione.

Nell'analisi dei modelli di apprendimento automatico esistenti sono stati selezionati due metodi, vale a dire le macchine vettoriali di supporto con ricottura simulata e un classificatore di Naive Bayes a doppio peso con metodi di coefficiente di compensazione. Il primo è stato proposto per prevedere l'auto-ossidazione per mancanza di ustioni, mentre il secondo ha mostrato buoni risultati nel prevedere il fumo e la presenza di una fiamma libera. Le concentrazioni di fumo e monossido di carbonio per NSC e ossigeno, anidride carbonica e monossido di carbonio, metano, etano ed etilene sono state selezionate come indicatori di combustione. La combinazione dei metodi prodotti porta a una precisione dell'86,8%.

I dati sperimentali mostrano che la combinazione dei due metodi ML può essere utilizzata per prevedere tre categorie di incendi nelle miniere di carbone: nessuna combustione, carbone fumante e fuoco aperto. Di conseguenza, per implementare la metodologia in altre miniere, sono necessarie ulteriori ricerche con cambiamenti nel tipo di carbone e aggiustamenti della temperatura e del flusso dell'aria dalle misurazioni effettive. Inoltre, il modello presentato nel documento può essere utilizzato per la simulazione al computer durante l'adattamento a nuove posizioni operative.

4.3 Un modello per la gestione della supply chain

4.3.1 Caso di studio

La gestione della catena di approvvigionamento (Supply Chain Management, SCM) integra tutti i collegamenti e i processi aziendali coinvolti nella catena di approvvigionamento attraverso il sistema di gestione delle informazioni.

L'applicazione di algoritmi di intelligenza artificiale al sistema SCM può realizzare la visualizzazione, l'automazione e la gestione intelligente di tutti gli anelli della catena di approvvigionamento. Ciò può aiutare efficacemente le aziende a ridurre i costi operativi e migliorare la loro capacità di rispondere alle richieste del mercato, aumentando così l'efficienza operativa complessiva. Un metodo efficace di selezione dei soggetti coinvolti è una base importante per un funzionamento dinamico e fluido della supply chain. Per affrontare il problema dell'elevato numero di attributi decisionali e del basso numero di campioni di dati per l'analisi delle decisioni, questo

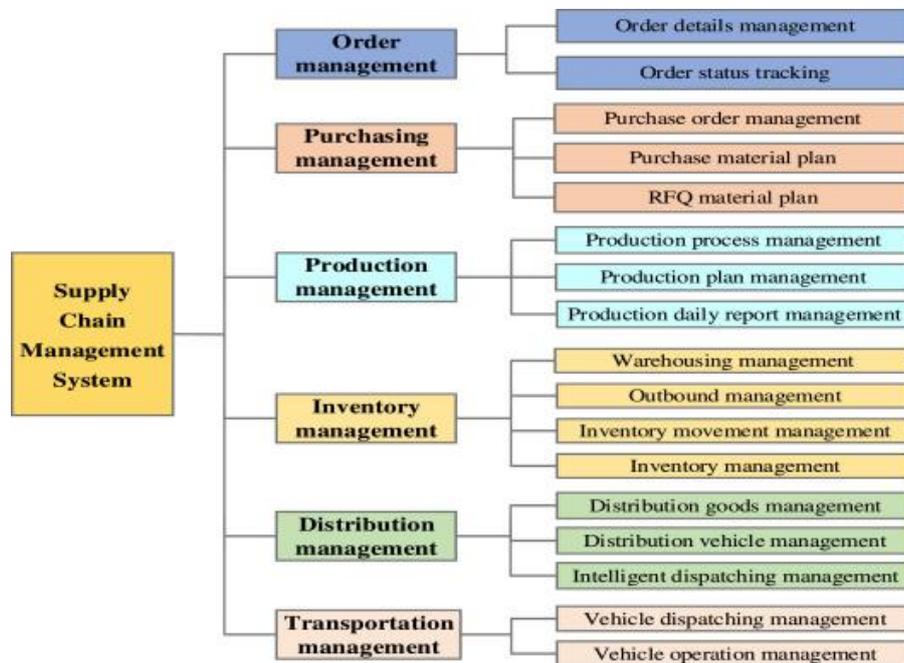
documento propone un algoritmo dinamico di selezione dei membri della supply chain basato su reti antagoniste generative condizionali (CGAN). Per garantire che le prestazioni di classificazione non vengano ridotte, il metodo di classificazione dei soggetti sulla catena può ridurre con successo la dimensione e la complessità dei dati nel processo di classificazione. Inoltre, l'apprendimento automatico viene utilizzato per analizzare e prevedere i collegamenti di acquisto e inventario nella catena di approvvigionamento. Per il modulo di pianificazione dei veicoli, il percorso è ragionevolmente pianificato per migliorare l'efficienza operativa. L'implementazione integrata del sistema SCM è finalizzata utilizzando il framework SSH.

4.3.2 Connessione e collaborazione di rete per la supply chain

L'essenza della collaborazione di connessione della rete della supply chain è realizzare cinque connessioni, vale a dire, collegare i clienti, collegare i fornitori, collegare i prodotti, collegare le apparecchiature di produzione e collegare i manager. Dopo la trasformazione intelligente della supply chain aziendale, queste cinque connessioni saranno collegate e diventeranno un nodo della supply chain. Si genererà un piccolo ciclo di connessioni tra clienti, fornitori, attrezzature di produzione, prodotti e gestione. Può anche essere collegato ad altri sistemi aziendali per formare un alto grado di collaborazione in rete della supply chain condividendo le informazioni.

In termini di integrazione e trasformazione dei dati logistici nella supply chain, le due tecnologie emergenti, machine learning e big data, possono essere utilizzate per realizzare la trasformazione in tempo reale dell'elaborazione dei dati logistici e

l'integrazione dei dati della supply chain utilizzando dispositivi terminali palmari mobili.

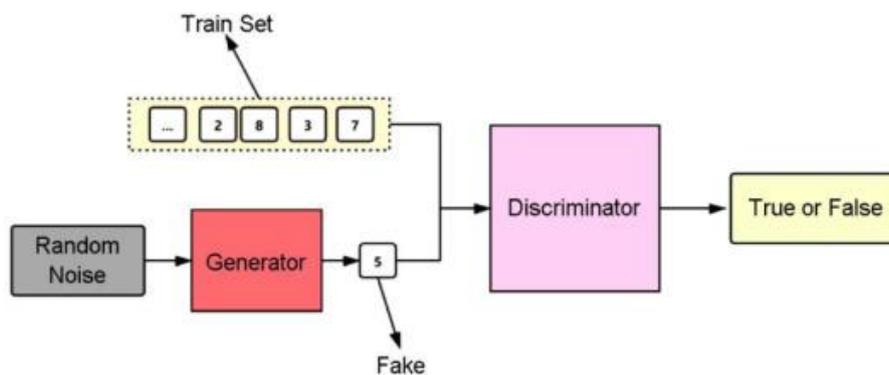


Come mostrato in figura, il sistema SCM progettato in questo studio è composto da moduli di ordine, acquisto, produzione, inventario, distribuzione e trasporto. Ogni modulo include il business corrispondente.

Il sistema combina anche l'algoritmo CGAN per analizzare l'indice dei dati. Sulla base della determinazione dei fattori rilevanti dei partner, mina gli schemi alternativi che i responsabili delle decisioni delle imprese principali nella catena di approvvigionamento utilizzano per costruire il rapporto di cooperazione, in modo da migliorare l'accuratezza e la completezza del processo decisionale. Può fornire supporto ai dati per la formulazione di piani di attività e l'assegnazione delle forze operative e di manutenzione.

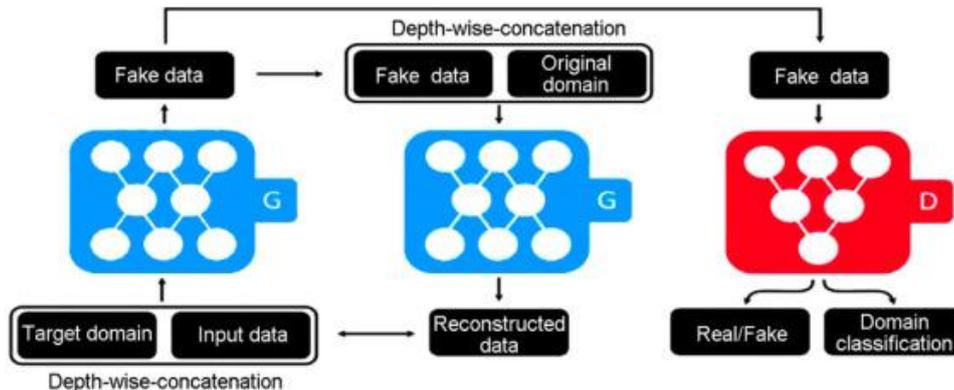
4.3.3 Metodo di selezione dinamica dei partner della catena di approvvigionamento

Il CGAN è composto da generatore e discriminatore. Il generatore riceve un segnale di rumore casuale (che può essere distribuito uniformemente o gaussiano) e genera il campione corrispondente. Il discriminatore riceve quindi i campioni reali e generati. La funzione del discriminatore è principalmente quella di giudicare l'autenticità del campione generato utilizzando un valore di probabilità. Il generatore rafforza continuamente la sua capacità di migliorare i campioni generati, fino a quando il discriminatore non è in grado di distinguere tra campioni reali e generati. La struttura del CGAN è mostrata in figura.



Il discriminatore di CGAN immette campioni (che possono essere reali o generati) e produce scalari corrispondenti (cioè valori di probabilità appartenenti ai campioni reali). All'inizio, poiché il generatore è relativamente debole, i campioni generati sono facilmente distinguibili; tuttavia, con il continuo rafforzamento del generatore, il discriminatore alla fine non è in grado di distinguere i due e, infine, può solo produrre una probabilità di 0,5 (indicando che la probabilità reale è uguale alla probabilità generata). Questo processo equivale a un processo di gioco massimo e minimo.

Il discriminatore continua a massimizzare la discriminazione nei campioni e il generatore continua anche a migliorare la sua capacità di generare campioni, raggiungendo infine un equilibrio di Nash. La figura mostra il generatore di CGAN.



In CGAN due reti neurali si confrontano in un gioco a somma zero. Il compito della prima rete, il generatore, è ingannare la seconda rete, il discriminatore. Il generatore crea dati "falsi", nel qual caso le due reti possono essere migliorate iterativamente. Queste reti possono essere considerate come scatole nere che rappresentano funzioni arbitrariamente complesse, applicate al rumore o ai dati reali. L'ingresso del generatore è un rumore casuale che produce una pseudo immagine. L'input del discriminatore include uno pseudo campione e un campione dal set reale. L'addestramento delle due reti richiede una funzione di perdita e la funzione di perdita di ciascuna rete dipende dall'altra rete. Per addestrare la rete, viene eseguita la back-propagation e i pesi dei neuroni di altre reti vengono contemporaneamente congelati. Generalmente, le reti di discriminatori e generatori possono assumere la forma di qualsiasi funzione di mappatura.

4.3.4 Conclusioni

I risultati sperimentali mostrano che la classificazione dei dati di CGAN è accurata, il livello di bilanciamento dei dati è elevato e la generalità complessiva è migliorata. Pertanto, CGAN è adatto per la selezione dei partner in catene di approvvigionamento dinamiche.

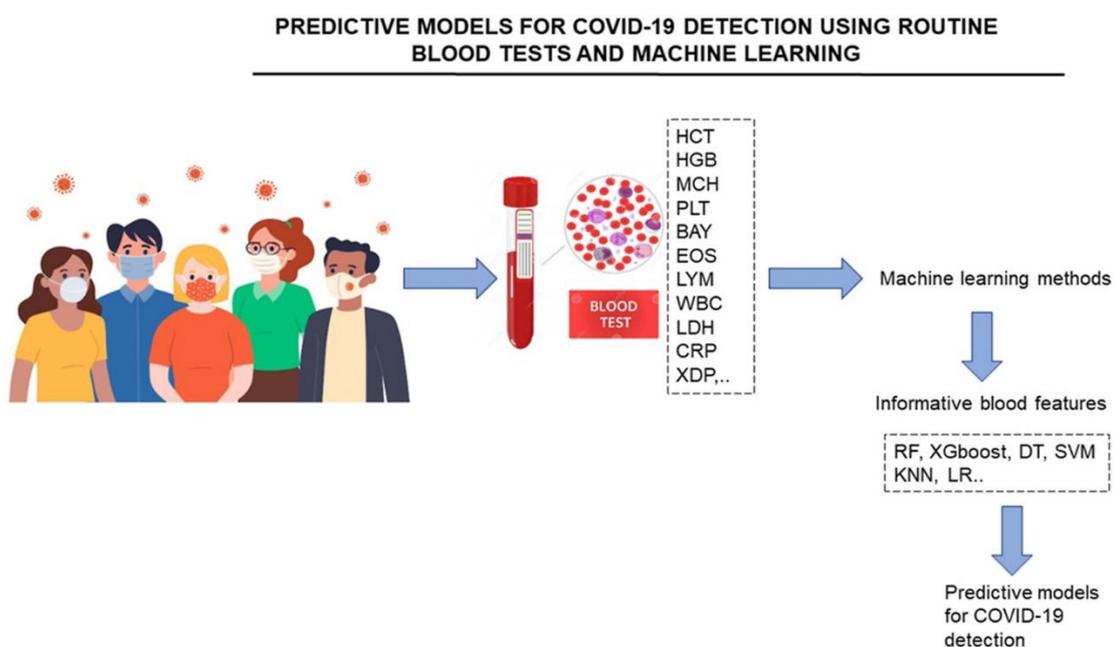
L'intelligenza artificiale offre al sistema della supply chain il potenziale tecnico per raggiungere questi requisiti. Può anche essere utilizzato per valutare, regolare la capacità di stoccaggio, modificare i piani di trasporto prevedendo il tempo e adeguando tempestivamente le decisioni aziendali utilizzando dati esterni. Una rete neurale è un sistema dinamico adattivo e non lineare costituito da ospiti di neuroni interconnessi che le consentono di eseguire complesse operazioni logiche. Come sistema di elaborazione dati, una rete neurale imita la struttura e la funzione del cervello umano. Queste reti possono eseguire risposte di stato a input continui o discontinui ed elaborare le informazioni dinamiche in relazioni non lineari. Una rete neurale è un sistema dinamico stabilito manualmente che utilizza un grafo diretto come struttura topologica. Elabora i dati effettuando risposte di stato a input continui o discreti. Il grafo che funge da struttura topologica rappresenta unità di elaborazione come nodi e archi diretti ponderati. Progettato per gestire i problemi di ricerca, l'algoritmo genetico è applicabile a molti tipi di problemi generali. Questo algoritmo si basa sulla ricerca parallela di un gruppo cromosomico utilizzando tre tipi di operazioni: selezioni, scambi e mutazioni. Questa combinazione rende l'algoritmo genetico unico. È probabile che gli algoritmi tradizionali rientrino nella soluzione ottimale locale, poiché iterano da un singolo valore iniziale. L'algoritmo genetico,

tuttavia, è efficiente per l'ottimizzazione globale grazie alla sua ampia copertura e base su un set di stringhe. È in grado di elaborare contemporaneamente molti individui in una popolazione. Poiché può valutare più soluzioni simultaneamente, l'algoritmo genetico non rischia quindi di cadere in una soluzione ottimale locale. Per utilizzare l'algoritmo genetico, non è richiesta alcuna conoscenza dello spazio di ricerca o disponibilità di informazioni ausiliarie, ad eccezione del valore della funzione di fitness, necessaria per la valutazione individuale. Questa funzione di fitness non è limitata dalla differenziabilità continua e il suo dominio di definizione può essere impostato arbitrariamente, ampliando così significativamente la gamma di applicazioni dell'algoritmo. Inoltre, l'algoritmo genetico segue regole di transizione probabilistiche, piuttosto che deterministiche, nel suo processo di ricerca grazie alle sue proprietà di auto-organizzazione, auto-adattamento e auto-studio. Quando l'algoritmo esegue una ricerca utilizzando dati derivati dal processo evolutivo, gli individui con elevata idoneità mostrano una maggiore probabilità di sopravvivenza e ricevono la struttura genica ottimale per l'ambiente. Sulla base di queste considerazioni, questo studio adotta la rete antagonista generativa condizionale (CGAN) per realizzare il metodo di selezione dinamica dei partner nella catena di approvvigionamento, utilizzando al contempo l'apprendimento automatico innovativo per l'analisi dei collegamenti di acquisto e inventario.

4.4 Modelli predittivi per il rilevamento del COVID-19

4.4.1 Caso di studio

Il problema dei test COVID-19 accurati, veloci e poco costosi è stato pressante fino ad oggi. I test standard richiedono reagenti ad alto costo e laboratori specializzati con elevati requisiti di sicurezza e richiedono molto tempo. I dati degli esami del sangue di routine come base del rilevamento dell'infezione SARS-CoV-2 consentono di utilizzare le strutture mediche più pratiche. Ma gli esami del sangue forniscono informazioni generali sullo stato di un paziente, che non sono direttamente associate a COVID-19. Le caratteristiche specifiche del COVID-19 dovrebbero essere selezionate dall'elenco delle caratteristiche standard del sangue e dovrebbe essere creato un software decisionale basato su dati clinici appropriati. Questa revisione di Yuri V. et al. [15] descrive le capacità di sviluppare modelli predittivi per il rilevamento di COVID-19 utilizzando esami del sangue di routine e apprendimento automatico.



Per stabilire le corrispondenti dipendenze latenti tra i parametri degli esami del sangue e la presenza di COVID-19, è necessario applicare un approccio di apprendimento automatico. I modelli di previsione più efficaci con un'accuratezza della diagnosi di COVID-19 di circa l'85-95% si basano sull'utilizzo di Random Forest, potenziamento del gradiente e delle loro variazioni. Sorprendentemente questi modelli non utilizzano più di 8-10 parametri del sangue.

L'attuale "gold standard" per l'identificazione dell'infezione da SARS-CoV-2 si basa su una reazione a catena della trascrizione-polimerasi (RT-PCR) e test di saggio immuno assorbente enzimatico (ELISA). La RT-PCR ha un'elevata specificità ma una bassa sensibilità e un'elevata classificazione errata nella fase iniziale della malattia. Gli svantaggi sono attrezzature e materiali di consumo ad alto costo, lunghi tempi di analisi. Ulteriori informazioni possono essere ottenute mediante tomografia computerizzata o visualizzazione a raggi X, ma questi metodi richiedono attrezzature ad alta tecnologia e non possono essere utilizzati spesso. Una possibile soluzione è quella di utilizzare test clinici più convenzionali combinati con metodi analitici sofisticati ma potenti nel campo dell'Intelligenza Artificiale implementati come il Medical Decision Support System (MDS). L'attrattiva di questa idea è che l'Intelligenza Artificiale può compensare una non specificità dei test clinici generali.

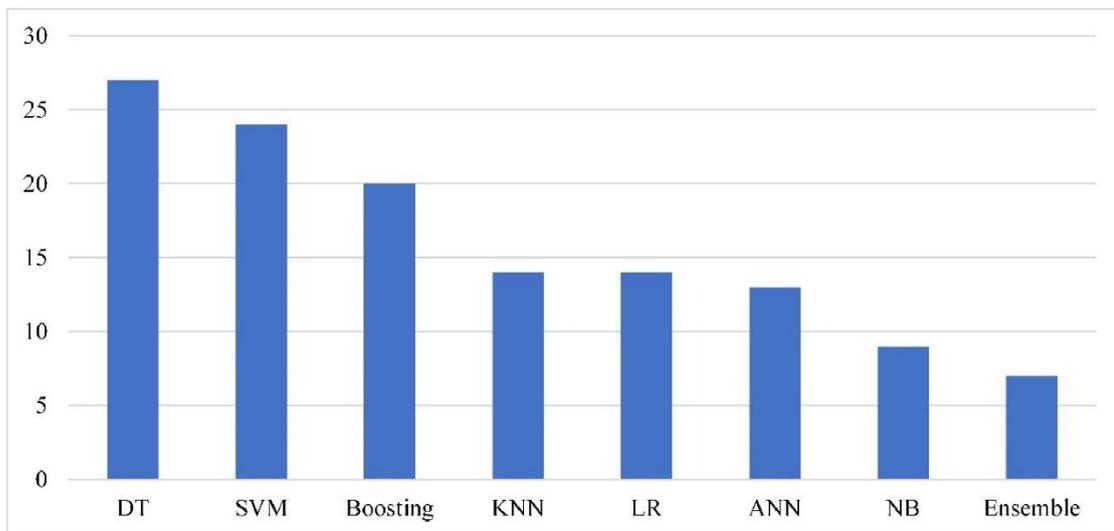
4.4.2 Selezione delle caratteristiche informative per l'esame del sangue

Gli autori hanno analizzato circa 50 articoli pubblicati su riviste nel campo della medicina e dell'apprendimento automatico e indicizzati su Scopus, Google Scholar e Web of Science. La ricerca includeva i seguenti termini: COVID-19, esami del sangue, Machine learning, analisi statistica.

In questo modo sono stati in grado di individuare le caratteristiche considerate informative per il rilevamento del COVID-19.

4.4.3 Metodi di machine learning applicati

I metodi di apprendimento automatico che hanno soddisfatto il maggior numero dei documenti analizzati dagli autori includono Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Decision Tree (DT), Boosting, Artificial Neural Network (ANN), Logistic regression (LR) (vedere la Figura). La popolarità dei metodi basati su DT, tra cui Random Forest (RF), Regression DT, ecc., è associata alla spiegabilità del modello di dati creato e all'eccellente precisione. In 9 casi i metodi basati su DT hanno dimostrato la migliore accuratezza di previsione. Una diagnosi COVID-19 basata su RF ha dimostrato un'accuratezza del 92,9%.



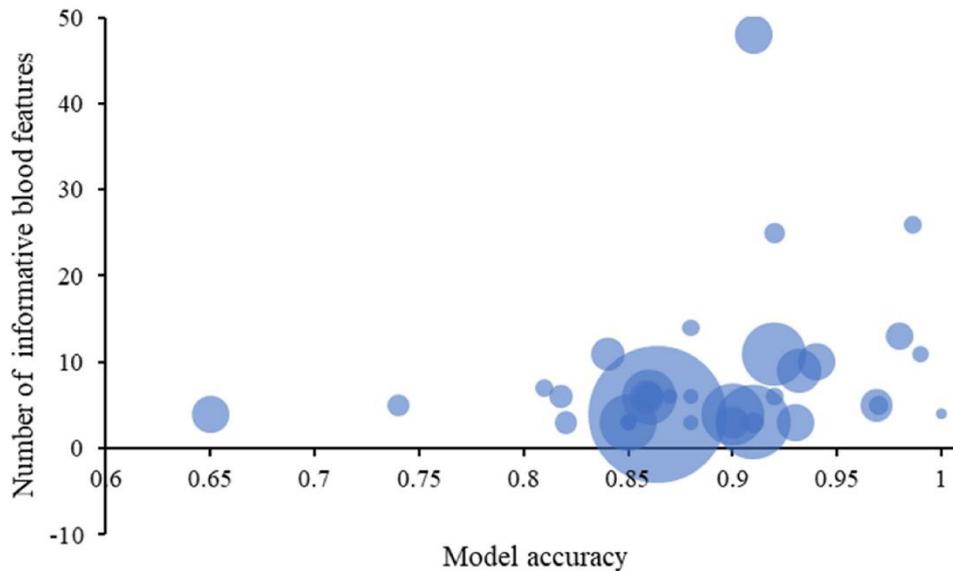
La frequenza dei vari metodi di classificazione utilizzati.

Il potenziale di generalizzazione SVM e le buone prestazioni sono le ragioni del suo uso frequente. La famiglia Boosting è al terzo posto in popolarità e al secondo posto di accuratezza delle previsioni (7 studi). La regressione logistica è efficace per l'estrazione di caratteristiche informative e robusta all'overfitting. I ricercatori stanno ancora usando KNN e Naive Bayes (NB), che erano tra i primi metodi di apprendimento supervisionato apparsi e non mostrano risultati elevati. Un'eccezione è la rete bayesiana con prestazioni diagnostiche del 95,2%.

I ricercatori sono ancora vigili riguardo l'utilizzo di ANN e Deep Neural Network (DNN) perché il numero di funzionalità nei dati grezzi è piccolo (decine) rispetto a un numero di campioni (centinaia), il che non è adatto a questi metodi.

L'accuratezza di un modello predittivo dipende dal volume e dalla qualità dei dati. Nei documenti analizzati, il set di dati più piccolo includeva 51 pazienti COVID-19, il più grande 7335. Il numero medio di pazienti COVID-19 è stato di 919. Il gruppo di controllo più ampio comprendeva 125.542 campioni. Il numero medio di

caratteristiche ematiche informative era 8, la mediana era 6. La precisione media era dell'88%. La semplicità dei migliori modelli predittivi è un argomento che ha evitato l'overfitting. Una relazione tra il numero di caratteristiche informative e l'accuratezza di un modello predittivo è mostrata in figura.



La figura mostra dataset e caratteristiche del modello predittivo. La dimensione della bolla corrisponde al numero di campioni COVID-19 verificati nel set di dati: più grande è, meglio è. L'asse verticale si riferisce al numero delle caratteristiche informative del sangue utilizzate. L'asse orizzontale descrive l'accuratezza del modello, presa dai documenti. Quando non era disponibile, veniva utilizzata un'approssimazione.

4.4.4 Conclusioni

I modelli di previsione più efficaci erano basati sull'utilizzo della foresta casuale, del potenziamento del gradiente e delle loro variazioni. Il modello predittivo ha raggiunto il punteggio di precisione più elevato con una dimensione del set di dati relativamente piccola che può essere oggetto di overfitting. I set di dati con oltre 500 campioni dimostrano un'accuratezza di circa l'85-95%, che può essere considerata molto buona. Tali risultati devono essere considerati positivi e specifici strumenti diagnostici orientati ai metaboliti del sangue dovrebbero essere utilizzati nella pratica clinica.

BIBLIOGRAFIA

- [1] G. Shankarrao Patange and A. Bharatkumar Pandya, How artificial intelligence and machine learning assist in industry 4.0 for mechanical engineers
- [2] Farah Sami, Optimize electric automation control using artificial intelligence (AI), Optik
- [3] Shiguang Sun, Dmitry Gura, Bo Dong, Fire safety assessment models based on machine learning methods for the coal industry, Chemometrics and Intelligent Laboratory Systems
- [4] Sebastian Raschka, Machine learning con phyton, Apogeo, 2015
- [5] Z. Zhang, Y. Cai and W. Gong, Semi-supervised learning with graph convolutional extreme learning machines. Expert Systems With Applications (2022)
- [6] S. Coulibaly, B. Kamsu-Foguem, D. Kamissoko et al. Machine Learning with Applications 10 (2022)
- [7] Claudio Mattiusi Dario Floreano. Manuale sulle reti neurali. 2002
- [8] V. Yepmo, G. Smits and O. Pivert Data & Knowledge Engineering 137, Anomaly explanation: A review (2022)
- [9] Simon Haykin. Neural Networks and Learning Machines Third Edition. 2009.
- [10] S. Hawkins, H. He, G. Williams, R. Baxter, Outlier detection using replicator neural networks, in: International Conference on Data Warehousing and Knowledge Discovery, Springer, 2002, pp. 170–180.
- [11] Cortes, C., Vapnik, V. Support-vector networks. Mach Learn 20, 273–297 (1995)
- [12] Yuwei Pan, Rainer Stark, An interpretable machine learning approach for engineering change management decision support in automotive industry, Computers in Industry, Volume 138, 2022

[13] Shiguang Sun, Dmitry Gura, Bo Dong, Fire safety assessment models based on machine learning methods for the coal industry, *Chemometrics and Intelligent Laboratory Systems*, Volume 231, 2022

[14] Haifeng Lin, Ji Lin, Fang Wang, An innovative machine learning model for supply chain management, *Journal of Innovation & Knowledge*, Volume 7, Issue 4, 2022

[15] Yury V. Kistenev, Denis A. Vrazhnov, Ekaterina E. Shnaider, Hala Zuhayri, Predictive models for COVID-19 detection using routine blood tests and machine learning, *Heliyon*, Volume 8, Issue 10, 2022

[16] L. Shu, H. Zhang, Y. You, Y. Cui, W. Chen, Towards fire prediction accuracy enhancements by leveraging an improved naïve bayes algorithm, *Symmetry* 13, 2021

RINGRAZIAMENTI

Trovo doveroso dedicare questo spazio a tutti coloro che in qualche modo mi sono stati a fianco durante tutto il mio percorso di laurea.

Voglio ringraziare innanzitutto il mio relatore, il Prof. M. Bevilacqua e il mio correlatore, il Prof. G. Mazzuto per la loro pazienza, disponibilità e per i loro consigli.

Ringrazio di cuore la mia famiglia per avermi sostenuto e aver sempre creduto in me.

Ringrazio tutti i miei amici e i miei compagni di corso per essere stati con me in questi anni. Con loro ho condiviso bellissimi momenti dentro e fuori dall'università.

In particolare, vorrei menzionare i ragazzi di Giulio fanpage: Simone, Andrea, Federico, Massimo, Alessio, Alessandro e Nicola; e i ragazzi di Belli c.: Federico, Stefano, Martina, Michele, Leonardo, Caterina, Asia, Antonia, Agnese, Lorenzo, Sofia L., Sofia N. e Valentina.

Vorrei ringraziare la società Volley 2001 Garlasco per avermi accolto e consentito di terminare il mio percorso di studi, in particolare tutta la dirigenza, lo staff, tutti i miei compagni di squadra e alcune delle ragazze della femminile che mi sono state accanto durante la stesura di questo elaborato.

Infine, vorrei ringraziare anche tutti coloro che mi hanno in qualche modo ostacolato durante questo percorso di laurea, per esempio convincendomi a uscire quelle sere in cui sarei dovuto rimanere in casa a studiare, poiché nonostante mi abbiano rallentato, hanno reso tutto più speciale: "Nobody queues for a flat rollecoaster".