

*Estimating the Effects of Urban Regeneration
on Real Estate Values*

STIMA DEGLI EFFETTI DELLA RIGENERAZIONE URBANA SUI VALORI IMMOBILIARI

Gabriella Maselli

*^aDICIV - Dipartimento di Ingegneria Civile, Università degli Studi di Salerno, via Giovanni Paolo II, 132,
84084 - Fisciano (SA), Italia
gmaselli@unisa.it*

Abstract

Urban regeneration interventions, increasingly implemented in response to the uncontrolled urbanisation of cities, can generate social, environmental, and economic benefits. This study aims to investigate how urban regeneration influences the price of residential real estate. This paper compares techniques commonly used in practice, such as Multiple Linear Regression (MLR), and innovative Artificial Intelligence (AI) models like Artificial Neural Networks (ANNs). The analysis shows that some of the criticalities of MLR, such as the inability to handle non-linearity and collinearity between variables, can be overcome by resorting to AI algorithms. However, the latter fail - for instance - to evaluate the marginal prices of input variables. Therefore, the research first aims to provide a panel of variables useful for predicting real estate values following changes in the quality of the urban environment. Then, a methodology that involves the joint use of MLR and ANN is defined. This is to demonstrate that AI models, when supported by traditional models, can return a broader set of information to valuers and represent a more valid support to decision-making.

KEY WORDS: *Urban Regeneration Interventions, Real Estate Value, Multiple Linear Regression, Artificial Neural Networks.*

1. Introduzione

Al giorno d'oggi, strategie di rigenerazione urbana sono una necessaria risposta al degrado dei beni ambientali causato dall'espansione incontrollata delle città.

Molteplici studi hanno dimostrato che la frammentazione dei beni ecologici urbani comporta conseguenze drammatiche, quali l'interruzione del sistema idrologico, la perdita di biodiversità e le interruzioni dei flussi di energia [1]. Per evitare un irreversibile degrado urbano, occorre investire sempre più sulla conservazione e sul ripristino delle aree verdi e blu, cosicché la città stessa possa diventare generatrice di risorse e di servizi ecosistemici.

Tali investimenti, inoltre, costituiscono un contributo tangibile che le città possono fornire all'agenda delle Nazioni

Unite e agli Obiettivi di Sviluppo Sostenibile [2]. Secondo il Millennium Ecosystem Assessment (MEA) [3], le reti di aree urbane e suburbane verdi e blu sono in grado di fornire quattro differenti tipi di servizi: (i) di approvvigionamento di acqua, cibo, fibre, legname e risorse genetiche; (ii) di regolazione del clima, qualità dell'acqua e il trattamento dei rifiuti; (iii) culturali, come la ricreazione, la realizzazione spirituale e il godimento estetico; e (iv) di supporto, quali la formazione del suolo, l'impollinazione e il ciclo dei nutrienti. I risultati del MEA hanno condotto diversi autori ad investigare gli effetti del ripristino dei servizi ecosistemici nelle aree urbane e, più in generale, delle politiche di riqualificazione urbana [4-7].

In questo quadro, diviene una grande sfida valutare i benefici monetari dei servizi ecosistemici forniti dalla natura

nelle aree urbane, comprese le attività ricreative e le amenità ambientali [8-10]. Ciò può essere fatto stimando l'incremento del prezzo degli immobili collocati nelle vicinanze di un'area coinvolta da interventi di rigenerazione urbana [11, 12]. Ki e Jayantha [13] dimostrano che un miglioramento dell'ambiente urbano determina benefici per la collettività, nonché un incremento dei prezzi dei valori immobiliari. Noor et al. [14] sottolineano che i prezzi delle proprietà immobiliari sono significativamente influenzati dalla presenza di spazi verdi, servizi e infrastrutture. Nesticò et al. [15] studiano i livelli di correlazione tra i prezzi degli immobili e la dotazione di verde urbano. Con questo paper s'intende dapprima confrontare gli approcci tradizionali di previsione del prezzo, ovvero basati sulla teoria del prezzo edonico, e i metodi innovativi di Intelligenza Artificiale (IA) e Machine Learning (ML). Quindi definiamo una Rete Neurale Artificiale (RNA), ancora scarsamente impiegata per valutare la variazione del prezzo degli immobili dovuto a cambiamenti della qualità dell'ambiente urbano. Tale modello, che include variabili ambientali di rado tenute in conto negli approcci IA-ML, intende rappresentare un valido supporto agli approcci tradizionali di previsione del prezzo ed essere un riferimento per decisori ed investitori immobiliari.

2. Stato dell'arte

2.1. Approcci tradizionali per la previsione del prezzo degli immobili

In letteratura sono stati sperimentati diversi approcci prevedere il prezzo delle abitazioni. Tra questi, il Metodo dei Prezzi Edonici (MPE) è tra i più ampiamente consolidati, soprattutto per la relativa semplicità di implementazione [16, 17]. Tale metodo si fonda sulla teoria del comportamento del consumatore di Lancaster, secondo la quale non è il bene in sé a creare utilità, ma le sue specifiche caratteristiche [18]. In accordo a tale teoria, il prezzo pagato per l'acquisto dell'immobile può essere scomposto in prezzi edonici (o impliciti) dei singoli attributi della proprietà [19]. Il prezzo implicito delle singole caratteristiche immobiliari viene generalmente stimato attraverso la Regressione Lineare Multipla (RLM).

Diverse sono le applicazioni che impiegano la RLM per valutare le esternalità ambientali e, più in generale, l'impatto di interventi di rigenerazione urbana sul valore di immobili residenziali. Solo per citarne alcuni, Zhang et al. [20] dimostrano che il verde urbano ha un'influenza positiva - e statisticamente significativa - sui valori delle proprietà vicine, che subiscono un incremento compreso tra il 5% e il 20%. Jim and Chen [21] stimano le esternalità positive causati dai parchi cittadini che offrono opportunità ricreative e servizi al vicinato e migliorano la qualità dell'ambiente e della vita. Chiarazzo et al. [22] stimano

l'impatto che inquinanti ambientali e disservizi ecosistemici, quali la distanza da un impianto industriale, generano sui valori immobiliari nella città di Taranto.

Nesticò e La Marca [23] dimostrano che vi è un'ampia area urbana a Salerno che risente degli effetti negativi delle attività industriali inquinanti, e che i prezzi degli immobili subiscono contrazioni fino al 43%. Ancora, Zhang and Zheng [24] documentano che una migliore qualità dell'aria è ricompensata dal mercato con prezzi delle abitazioni più alti.

Nonostante l'MPE sia un approccio consolidato ed ampiamente accettato, sia da professionisti che accademici, ha come principale limite quello di non tenere in conto della possibile non-linearità tra variabile dipendente (il prezzo della proprietà) e variabili indipendenti (ovvero le caratteristiche immobiliari) [17]. Un secondo limite è che non riesce a considerare i possibili effetti di correlazione tra le variabili. In aggiunta, il campione deve essere ampio e i dati uniformemente distribuiti nello spazio.

Se così non fosse, la previsione teoricamente non potrebbe garantire l'accuratezza dell'output. Infine, i risultati possono andare contro quelli derivanti dall'analisi qualitativa, tanto da non riuscire a definire una coerente equazione di regressione [23, 25].

Modelli di previsione dei prezzi più sofisticati di quelli analizzati riescono a superare il problema della relazione non lineare tra i dati di input e di output. Tra gli altri, vale citare l'Evolutionary Polynomial Regression (ERP) e i modelli polinomiali [25]. Approcci econometrici spaziali, quali il modello autoregressivo (Simultaneous Autoregressive Model, SAR), il modello spaziale a correzione dell'errore (Spatial Error Model, SEM), il modello di autocorrelazione spaziale (Spatial Autocorrelation Model, SAC), la regressione geografica pesata (Geographically Weighted Regression, GWR) riescono a tener conto della dipendenza e dell'eterogeneità spaziale, includendo variabili spaziali "ritardate" [26]. Tali modelli, che non sempre riescono a raggiungere risultati significativamente più performanti della RLM, possono risultare più complessi da implementare.

2.2. Approcci di Intelligenza Artificiale per la previsione del prezzo degli immobili

Una possibile alternativa agli approcci tradizionali di previsione dei prezzi è data dai modelli di Intelligenza Artificiale (IA) e di Machine Learning (ML), che hanno di recente trovato ampia applicazione in diversi settori industriali e commerciali [26-28]. Studi affermano che le Reti Neurali Artificiali (RNA), inclusi tra i modelli IA-ML, risultano un efficace strumento per la previsione del prezzo degli immobili [17]. Il loro principale vantaggio consiste nella capacità di definire relazioni non lineari tra input e output, condizione che spesso si verifica in ambito immobiliare. Diversi autori dimostrano che le reti neurali

potrebbero avere un grande potenziale per prevedere serie temporali economiche e finanziarie, anche eterogenee [28].

Le RNA sono tecniche di modellazione altamente sofisticate, che consentono di realizzare funzioni di progetto con un livello di complessità molto elevato, simulando il comportamento del cervello umano. L'unità minima di elaborazione della rete è il neurone artificiale, che è costituito da input, nodi, pesi ed output. I dati di input corrispondono ai terminali dei neuroni interconnessi; i pesi rappresentano le sinapsi di collegamento assone-dendriti; il nodo costituisce il corpo cellulare, ovvero il luogo di rielaborazione dei dati; infine, l'output rappresenta l'informazione in uscita trasmessa dall'assone del neurone in esame. I pesi associati ad ogni neurone sono calcolati attraverso un processo di prova-errore detto di apprendimento.

Selezionando un set adeguato di pesi di collegamento e funzioni di trasferimento, una RNA può imparare a raggiungere un determinato compito. Generalmente, le RNA sono costituite da più strati di neuroni artificiali collegati tra loro:

- l'*input layer*, che include le variabili indipendenti del problema;
- l'*output layer*, che trasmette il risultato all'ambiente esterno;
- l'*hidden layer*, che stabilisce collegamenti tra gli strati di input e di output – tramite la funzione di trasferimento selezionata – e fornisce la generalizzazione della rete [29].

In sintesi, per costruire una rete neurale occorre definire:

- l'architettura, stabilendo il numero di layer, il numero di neuroni contenuti in ogni layer e la presenza di eventuali connessioni di retroazione;
- la funzione di attivazione, che determina il tipo di risposta che un neurone è in grado di emettere e può essere di diversi tipi (a gradino o soglia, continua lineare, continua non lineare, ...);
- l'algoritmo di apprendimento, che ha la funzione di addestrare la rete, andando a modificare gradualmente i pesi sinaptici, in modo da minimizzare tra output e target. Si possono distinguere due diverse modalità di apprendimento: supervisionato, se è necessario fornire alla rete possibili input e relativi output; non supervisionato, se occorre fornire solo gli input [30].

Con specifico riferimento alla previsione dei valori immobiliari, la letteratura ha dimostrato che le RNA potrebbero condurre a previsioni altamente accurate ed attendibili [29]. Al riguardo, sono state condotte sperimentazioni con diversi scopi ed in contesti geografici differenti. Imran et al. [16] impiegano algoritmi di

apprendimento automatico per definire modelli di regressione intelligenti a supporto della previsione del valore degli immobili in Pakistan. Morano et al. [30] caratterizzano una RNA per prevedere valori di mercato degli immobili residenziali di un quartiere della città di Bari (Italia). Ćetković et al. [31] impiegano la RNA per stimare i prezzi delle proprietà residenziali nei Paesi Europei e dimostrano che tali valori dipendono anche da variabili macroeconomiche. Con algoritmi di IA, Kitapci et al. [32] intendono supportare investitori immobiliari, fornendogli più efficaci indicazioni sui prezzi delle proprietà ad Ankara (Turchia). Kalliola et al. [17] dimostrano che le RNA possono raggiungere risultati altamente accurati prevedendo i prezzi delle abitazioni in un quartiere di Helsinki, in Finlandia.

In letteratura si evincono anche alcuni tentativi di definire modelli IA-ML, avanzati o ibridi, in grado di raggiungere altissimi livelli di performance. Abidoye et al. [33] definiscono un modello ibrido basato sull'uso congiunto della RNA, Support Vector Machine (SVM) e standard Autoregressive Integrated Moving Average (ARIMA) per prevedere valori immobiliari fuori campione. Ho et al. [34] confrontano tra loro diversi algoritmi di apprendimento automatico - SVM, Random Forest (RF) e Gradient Boosting Machine (GBM) - per la valutazione del prezzo degli immobili ad Honk Kong usando i dati di transazioni per un periodo di 18 anni.

Principale limite delle RNA è che il risultato è sensibilmente influenzato dalle informazioni input del sistema di studio, nonché dagli algoritmi di addestramento della rete. Un secondo limite è che gli elementi che costituiscono la rete - inclusi input, funzione di trasferimento e numero di layer nascosti - devono essere stabiliti a priori dal decisore. Inoltre, le RNA non sono in grado di incorporare leggi economiche nei processi di apprendimento [30].

Dagli studi analizzati emerge che alcuni aspetti della modellazione RNA risultano lacunosi, pertanto devono essere ulteriormente indagati. La letteratura ha restituito modelli molto differenti per: (i) numero di variabili input; (ii) dimensioni del campione; (iii) architetture del modello e rapporto di addestramento. Per quanto riguarda il punto (i), il numero di variabili adoperate è all'incirca compreso tra 6 e 40 e non vi sono indicazioni sul set ottimale di fattori input da considerare.

Ci sono opinioni discordanti anche sulle dimensioni del campione di dati (ii): in alcuni modelli la dimensione del panel di dati input è dell'ordine delle migliaia; in altri studi si dimostra che è possibile ottenere risultati relativamente buoni ricorrendo a poche centinaia di dati [30]. Infine, anche l'architettura del modello (iii) gioca un ruolo fondamentale in ogni RNA: più è elevato il numero di neuroni nascosti, più la soluzione può essere complessa. Inoltre, poiché le architetture sono state valutate in condizioni sperimentali molto diverse, vi è ancora discor-

danza su quale sia in grado di restituire risultati più accurati. Altra questione che merita approfondimento riguarda proprio l'inclusione nei modelli RNA di variabili ambientali, nonché applicazioni utili a prevedere i prezzi degli immobili a seguito di cambiamenti della qualità dell'ambiente urbano. Difatti, negli studi citati, le variabili input riguardano principalmente caratteristiche immobiliari intrinseche (superficie dell'appartamento, livello di piano, numero di bagni, età dell'edificio, etc.) e alcune caratteristiche estrinseche o zonali (ad es. la distanza dai principali servizi).

Tra i pochi riferimenti che includono variabili ambientali nel modello RNA, Chiarazzo et al. [35] stimano i prezzi di vendita di proprietà residenziali in un'area urbana altamente inquinata e identificano i fattori ambientali che in una città industriale maggiormente influenzano le scelte di ubicazione residenziale.

In conclusione, dal confronto tra gli approcci tradizionali e i modelli di IA, emerge che questi ultimi, oltre a restituire risultati molto performanti, riescono ad impostare relazioni non lineari tra input e output. Tuttavia, implementando la RLM, è possibile stimare i prezzi marginali delle singole variabili che influenzano la funzione prezzo. Tramite la RNA, invece, si riesce solo ad identificare le variabili input più significative.

3. Materiali e Metodi

Obiettivo del lavoro è caratterizzare una metodologia in grado di valutare l'effetto generato da cambiamenti della qualità dell'ambiente urbano sul prezzo degli immobili residenziali. Nello specifico, si intende definire un modello previsionale di semplice implementazione pratica, che restituisca risultati performanti e che permetta sia di individuare le variabili ambientali più significative, sia di stimare tali esternalità. Pertanto, proponiamo un'innovativa RNA nella quale sono incluse variabili ambientali, di rado tenute in conto negli approcci di ML. In parallelo, costruiamo anche un modello di Regressione Lineare Multipla (RLM) con le stesse variabili input su cui si basa l'RNA, per fornire anche indicazioni sui prezzi marginali dei fattori ambientali. Difatti, si ritiene che l'uso congiunto di modelli tradizionali e modelli innovativi IA-ML possano restituire al decisore un più ampio e più rigoroso set di risultati e di informazioni sulla struttura del mercato immobiliare.

Di seguito si descrivono le quattro fasi della metodologia.

Fase 1: Scelta delle caratteristiche immobiliari e raccolta dei dati. Si individuano le caratteristiche intrinseche ed estrinseche che influenzano il meccanismo di formazione del prezzo dell'immobile. Di seguito si riporta un set di fattori, che rappresentano le variabili indipendenti sia della RNA che della funzione di regressione. Da tale panel, l'analista potrà selezionare gli indicatori utili a calibrare i modelli

sulla base delle specifiche caratteristiche sociali, economiche, ambientali dell'area di studio e della disponibilità di dati.

Selezionate le variabili del modello, si procede alla raccolta dati. Si tratta di una fase fondamentale, poiché dati errati ed incoerenti possono influire sulla bontà del risultato.

La Tabella (vedi Tab. 1) restituisce il panel delle caratteristiche immobiliari.

Caratteristica	Descrizione	Unità di misura
Intrinseche		
Superficie	Superficie tot. dell'abitazione	Cardinale (m ²)
Livello	Livello di piano (1°, 2°, 3°)	Cardinale (1, 2, 3 etc.) o dummy (0, 1)
Bagni	Numero di bagni	Cardinale
Conservazione	Stato di conservazione dell'abitazione	(Discreta 1 - pessima, 3- buono, 5 - eccellente)
Ascensore	Presenza dell'ascensore	Dummy (1;0)
Giardino	Presenza del giardino	Dummy (1;0)
Garage	Presenza del garage	Dummy (1;0)
Terrazza	Presenza di terrazze	Dummy (1;0)
Tipo di abitazione	Appartamento, Terrazza, Casa indipendente	Dummy (per ogni tipo di abitazione)
Orientamento	Esposizione rispetto alla luce solare	(Discreta 1 - pessima, 3- buono, 5 - eccellente)
Sicurezza	Presenza di allarme	Dummy (1;0)
Climatizzazione	Presenza di sistemi di condizionamento	Dummy (1;0)
Età	Età o epoca di costruzione dell'immobile	Dummy (per range di età)
Estrinseche		
Densità abitativa del lotto	N. di abitanti per area	Cardinale (ab/km ²)
Servizi	Numero di ristoranti, vendita al dettaglio, sportelli bancomat etc.	Cardinale (N.)
Scuole	Presenza di scuole primarie e/o secondarie (entro 500 m)	Dummy (1;0)
Reddito	Reddito medio per area	Cardinale (€)
Disoccupazione	Tasso di disoccupazione per area	Cardinale (%)
Centro	Distanza dal centro storico e/o finanziario	Cardinale (m)
Metropolitana, ferrovia, aeroporto	Distanza dai principali servizi di trasporto	Cardinale (m)
Bus	Linea di autobus entro 500 m Numero totale di linee che servono l'area	Dummy (1;0) Cardinale (N.)
Costa marina	Distanza dalla costa	Cardinale (km)
Area pedonale	Distanza da area pedonale	Cardinale (m)
Spazi verdi	Distanza da spazi verdi (parchi urbani)	Cardinale (km)
Disservizi ecosistemici	Distanza da diss. Ecos. (impianti industriali)	Cardinale (km)
Spazi aperti degradati	Distanza da spazi aperti degradati	Cardinale (km)
Rigenerazione urbana	Distanza da un'area riqualificata	Cardinale (km)
Qualità ambientale	Qualità ambientale percepita o misurazione degli inquinanti	Discreta (per livelli) o cardinale (per es. µg/m ³)
Inquinamento acustico	Livello sonoro percepito o misurato	Discreta (per livelli)

Tab. 1 - Caratteristiche immobiliari intrinseche ed estrinseche. (fonte: propria elaborazione)

Fase 2: Configurazione e implementazione della RNA. Si caratterizza una rete a tre strati - ovvero layer input, layer nascosto e layer di output - in quanto generalmente preferita per la risoluzione di problemi previsionali. Per cui, prima di addestrare la rete, il decisore deve specificare:

il numero di neuroni n_i nello strato di ingresso; il numero di strati nascosti ed il numero di neuroni n_h in ognuno di questi strati; il numero di neuroni n_o nello strato di uscita. n_i corrisponde al numero di caratteristiche immobiliari selezionate dal panel della tabella (vedi Tab. 1), a seconda delle specificità del caso studio e dei dati disponibili.

L'output è dato dal prezzo degli immobili, per cui $n_o = 1$. Non vi è alcuna regola per stabilire univocamente n_h , pertanto il numero ottimale di neuroni nascosti è trovato tramite un processo iterativo per tentativi ed errori.

Ogni neurone artificiale è costituito da n connessioni input (A) le quali ricevono segnali dagli altri neuroni (o unità base), unitamente ad una 'bias adjustment' (per regolare la distorsione del segnale ricevuto) e ad un set di pesi per ogni connessione input. Poi, una funzione di trasferimento somma gli input pesati e la bias per decidere il valore dell'output derivante da quell'unità base. Nello specifico, l'output (O_j) per il generico nodo j deriva dall'applicazione di una funzione di trasferimento ϕ alla somma di tutti i segnali derivanti dalla singola connessione A_i moltiplicati per il valore del peso W_{ij} della connessione i entrante nel nodo j :

$$O_j = \phi (\text{Sum}_j) \quad (1)$$

$$\text{Sum}_j = \sum_i (W_{ij} \cdot A_i) \quad (2)$$

Nel caso in esame, si ritiene di dover caratterizzare una rete feedforward Multi-Layer Preceptron addestrata mediante l'algoritmo di back-propagation Levenberg - Marquardt, poiché ampiamente preferita per problemi di classificazione o previsione [36]. Per identificare il numero ottimale di neuroni nascosti e la soglia ottimale di errore interno, applichiamo un processo di prova ed errore.

La funzione di attivazione per il layer nascosto è sigmoidea. Prima di addestrare la rete, i dati input vengono normalizzati a [0,1]:

$$X_i = (X_i - X_{\min}) / (X_{\max} - X_{\min}) \quad (3)$$

Il set di dati normalizzati è poi diviso in tre diversi campioni in modo casuale: il 70% è usato come set di addestramento della rete e i restanti dati sono equamente divisi tra set di convalida, per misurare la generalizzazione della rete, e set di test, per valutare le prestazioni della rete durante e dopo l'addestramento. Occorre infine impostare il numero di neuroni nascosti sulla base della misura di performance della rete.

L'RNA più performante è valutata tramite lo scarto quadratico medio (Root Mean Square Error, RMSE) e l'indice di regressione R^2 :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \widehat{P}_i)^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - \widehat{P}_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (5)$$

Dove: P_i è il prezzo osservato dell' i -esima abitazione; \widehat{P}_i è il prezzo stimato; \bar{P} è il prezzo medio ed n corrisponde al numero di osservazioni. Il modello scelto sarà quello con R^2 più prossimo all'unità e con RMSE più basso.

Infine, per valutare le variabili input più significative, si effettua un'analisi di sensibilità. Dunque, la fase di addestramento dell'RNA viene ripetuta tante volte quante sono le caratteristiche immobiliari, eliminando ogni volta una delle variabili input. La significatività di ciascuna variabile input eliminata è valutata in funzione del valore R^2 che si ottiene alla fine di ogni procedura di addestramento. In altri termini, al diminuire del valore R^2 , aumenta la significatività della variabile rimossa [35].

Fase 3: Stima dei prezzi marginali mediante RLM. Definiamo una funzione di regressione del tipo:

$$Y = X \cdot \beta + \varepsilon \quad (6)$$

Nella (6): Y è un vettore ($n \times 1$) dei prezzi delle singole abitazioni, generalmente specificato in termini logaritmici; X è una matrice (di dimensione $n \times k$) con k variabili indipendenti, rappresentate dalle caratteristiche immobiliari (intrinseche ed estrinseche), scelte tra quelle suggerite in tabella (vedi Tab. 1); β è il vettore dei k coefficienti da stimare o regressori, che rappresentano i prezzi marginali delle n caratteristiche immobiliari; ε è un vettore ($n \times 1$) di errori indipendenti e identicamente distribuiti; n il numero di osservazioni. Una volta calibrato ed implementato il modello, occorre sia verificare le ipotesi su cui si basa la regressione multipla, che valutare l'accettabilità dei risultati.

Le ipotesi da validare riguardano: la normalità delle distribuzioni condizionate e la linearità delle relazioni tra le variabili (Q-Q plot); l'omoschedasticità (analisi dei residui); l'esistenza di una relazione significativa tra la variabile dipendente P e l'insieme delle variabili esplicative (test-F); la significatività di ciascuna delle variabili esplicative del modello (test t). L'accettabilità dei risultati è verificata valutando gli indici di determinazione R^2 , R^2_{corr} , ed il criterio di Akaike (Akaike's Information Criterion, AIC).

Fase 4: Confronto dei risultati. Dal confronto dei risultati ottenuti dagli step 2 e 3, è possibile ricavare importanti informazioni: (a) quale dei due modelli - RNA e RLM - restituisce risultati più performanti in termini di R^2 e RMSE per la rete neurale, e in termini di R^2 e R^2_{corr} per la regressione multipla; (b) le variabili di input più significative, con particolare attenzione a quelle ambientali; (c) la stima dei prezzi marginali di ciascuna caratteristica immobiliare tramite la MRA.

La figura (vedi Fig. 1) schematizza gli step logico-operativi da seguire.

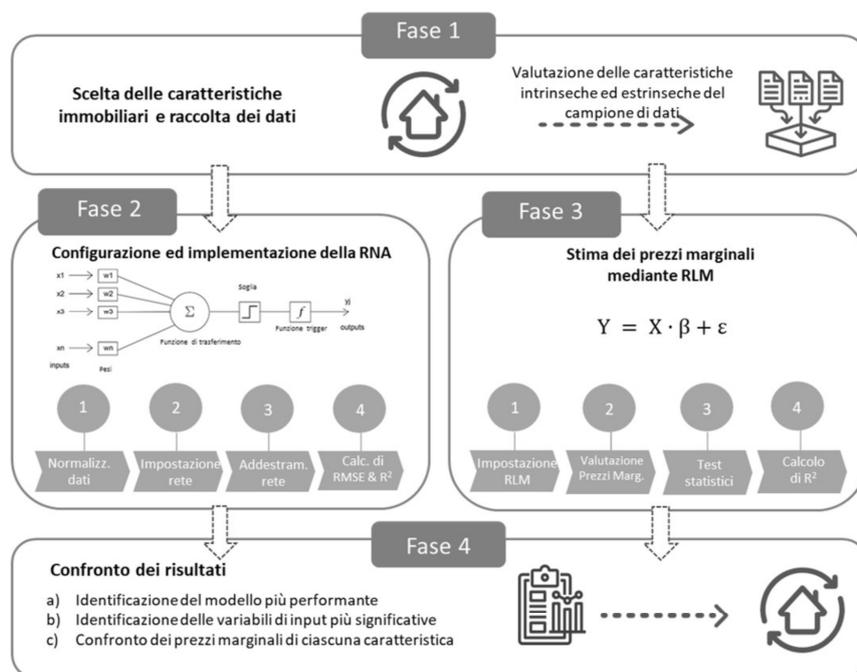


Fig. 1 - Fasi della metodologia.
 (fonte: propria elaborazione)

4. Conclusioni

Le iniziative d'investimento volte alla riqualificazione urbana, se ben pianificate, non solo restituiscono una nuova vita a quartieri fatiscenti, ma generano esternalità ambientali, sociali e culturali sul territorio circostante. Pertanto, tali processi oltre a migliorare la qualità dell'ambiente urbano, determinano un incremento del valore mercantile delle proprietà nel quartiere interessato dagli interventi di recupero.

Questo studio intende proporre una metodologia che permetta di valutare la variazione dei prezzi degli immobili residenziali causato da cambiamenti delle condizioni ambientali. Dalla disamina critica della letteratura emerge che i modelli di regressione tradizionali non sempre restituiscono risultati efficaci, in quanto non tengono in conto dell'eventuale non-linearità tra la variabile dipendente (il prezzo dell'immobile) e le variabili indipendenti (le caratteristiche immobiliari). In aggiunta, tali approcci non riescono a considerare la correlazione tra le variabili.

Pertanto, analizzando le potenzialità predittive degli approcci IA-ML emerge che questi ultimi riescono a definire relazioni non lineari tra input e output e restituiscono tendenzialmente risultati con un'elevata precisione statistica. Alla luce di questa analisi, con questo studio s'intende fornire: (a) un set di caratteristiche immobiliari e di indicatori ambientali e sociali che influenzano la funzione prezzo; (b) un'innovativa RNA nella quale sono incluse variabili ambientali, di rado tenute in conto negli approcci di ML. Tale modello può rappresentare un utile supporto agli approcci tradizionali basati sulla RLM.

Infatti, se congiuntamente implementati, i due approcci possono restituire a pianificatori ed investitori un quadro più completo di informazioni sui trend immobiliari, nonché

rappresentare un utile supporto al processo decisionale. Tale studio rappresenta solo il punto di partenza della ricerca. Applicazioni a casi studio reali permetteranno di testare l'RNA definita e restituire un confronto tra i risultati derivanti dagli approcci tradizionali e quelli ottenibili da modelli AI-ML.

Bibliografia

- [1] Assadpour N., Melles G.: *Participation in urban renewal projects in Iran: An initial review of Mashhad, Shiraz and Tehran*. Development Bulletin - Australian Development Studies Network 79, 2018
- [2] UNEP: *Towards a Green Economy: Pathways to Sustainable Development and Poverty Eradication - A Synthesis for Policy Makers*, 2001. Maggiori informazioni su: www.unep.org/greeneconomy
- [3] M.E.A.: *Millennium Ecosystem Assessment, Ecosystems and Human Well-being: Synthesis*. Island Press, Washington, DC, 2005
- [4] Mehdipanah R., Marra G., Melis G., Gelormino E.: *Urban renewal, gentrification and health equity: a realist perspective*. In: *European Journal of Public Health* vol. 28, n. 2, pp. 243 - 248, 2018
- [5] Morano, P., Guarini M.R., Sica F., Anelli D.: *Ecosystem Services and Land Take. A Composite Indicator for the Assessment of Sustainable Urban Projects*. In: Gervasi O. et al. (ed.): *International Conference on Computational Science and Its Applications*, pp. 210 - 225. Springer, Cham, 2021
- [6] Della Spina L., Giorno C., Galati Casmiro R.: *Bottom-Up Processes for Culture-Led Urban Regeneration Scenarios*. In: Misra S. et al. (ed.): *Computational Science and Its Applications - ICCSA 2019. Lecture Notes in Computer Science*, vol. 11622, pp.93 - 97. Springer, Cham, 2019
- [7] Troisi R., Castaldo P.: *Technical and organizational challenges in the risk management of road infrastructures*. In: *Journal of Risk Research*, 2022
- [8] Bencardino M., Nesticò A.: *Demographic Changes and Real Estate Values. A Quantitative Model for Analyzing the Urban-Rural Linkages*. In: *Sustainability*, vol. 9(4), n. 536, 2017

- [9] Dolores L., Macchiaroli M., De Mare G.: *A dynamic model for the financial sustainability of the restoration sponsorship*. In: Sustainability vol. 12 (4), n. 1694, 2020
- [10] Maselli G., Nesticò A.: *L'Analisi Costi-Benefici per progetti in campo ambientale. La scelta del Saggio Sociale di Sconto*. In: LaborEst n. 20, pp. 99 - 104, 2020
- [11] Spampinato G., Malerba A., Calabrò F., Bernardo C., Musarella C.: *Cork oak forest spatial valuation toward post carbon city by co2 Sequestration*. In: Bevilacqua C., Calabrò F., Della Spina L. (eds): *New Metropolitan Perspectives*. NMP 2020. Smart Innovation, Systems and Technologies, vol. 178, pp. 1321 - 1331, 2021
- [12] Troisi R., Alfano G.: *Is regional emergency management key to containing COVID-19? A comparison between the regional Italian models of Emilia-Romagna and Veneto*. In: International Journal of Public Sector Management, 2021
- [13] Ki C., Jayantha W.: *The Effects of Urban Redevelopment on Neighbourhood Housing Prices*. In: International Journal of Urban Sciences vol. 14, n. 3, 2010
- [14] Noor N., Asmawi M. Z., Abdullah A.: *Sustainable Urban Regeneration: GIS and Hedonic Pricing Method in determining the value of green space in housing area*. In: Procedia - Social and Behavioral Sciences n. 170, pp. 669 - 679, 2015
- [15] Nesticò A., Endreny T., Guarini M. R., Sica F., Anelli D.: *Real estate values, tree cover, and per-capita income: an evaluation of the interdependencies in Buffalo City (NY)*. In: Gervasi O. et al.: *International Conference on Computational Science and Its Applications*, pp. 913 - 926. Springer, Cham, 2020
- [16] Imran I., Zaman U., Waqar M., Zaman A.: *Using Machine Learning Algorithms for Housing Price Prediction: The Case of Islamabad Housing Data*. In: Soft Computing and Machine Intelligence Journal, n. 1, vol- 1, pp. 11 - 23, 2021
- [17] Kalliola J., Kapočūtė-Dzikienė J., Damaševičius R.: *Neural network hyperparameter optimization for prediction of real estate prices in Helsinki*. In: PeerJ Computer Science, n. 7, 2021
- [18] Lancaster K. J.: *A new approach to consumer theory*. In: The Journal of Political Economy, vol. 74, n. 2, pp. 132 - 157, 1966
- [19] Capello R.: *Una valutazione di accessibilità e qualità urbana: Una stima di prezzi edonici nella città di Trento*. In: Metodologie nelle Scienze Regionali. Franco Angeli: Milano, Italy, 2004
- [20] Zhang B., Xie G., Xia B., Zhang C.: *The effects of public green spaces on residential property value in Beijing*. In: Journal of Resource and Ecology, vol. 2, n. 3, pp. 243 - 252, 2012
- [21] Jim C. Y., Chen W. Y.: *External effects of neighbourhood parks and landscape elements on high-rise residential value*. In: Land Use Policy vol. 27, n. 2, pp. 662 - 670, 2010
- [22] Chiarazzo V., dell'Olio L., Ibeas Á., Ottomanelli M.: *Modeling the Effects of Environmental Impacts and Accessibility on Real Estate Prices in Industrial Cities*. In: Procedia - Social and Behavioral Sciences, n. 111, pp. 460 - 469, 2014
- [23] Nesticò A., La Marca M.: *Urban Real Estate Values and Ecosystem Disservices: An Estimate Model Based on Regression Analysis*. In: Sustainability, vol. 12(16), n. 6304, 2020
- [24] Zhang L., Zheng H.: *Public and Private Provision of Clean Air: Evidence from Housing Prices and Air Quality in China*, 2019. Maggiori informazioni su: SSRN 3214297
- [25] Wang C.: *House Price Prediction Model Based on Neural Network*, 2021
- [26] Efthymiou D., Antoniou C.: *Measuring the effects of transportation infrastructure on real estate prices and rents. Investigating the potential current impact of a planned metro line*. In: EURO Journal on Transportation and Logistics, n.3, 2013
- [27] Cioffi R., Travaglioni M., Piscitelli G., Petrillo A., De Felice F.: *Artificial intelligence and machine learning applications in smart production: progress, trends, and directions*. In: Sustainability, vol. 12(2), n. 492, 2020
- [28] Xu X., Zhang Y.: *House price forecasting with neural networks*. In: Intelligent Systems with Applications vol. 12, n. 200052, 2021
- [29] Karasu S., Altan A., Saraç Z., Hacıoglu R.: *Estimation of fast varied wind speed based on narx neural network by using curve fitting*. In: International Journal of Energy Applications and Technologies n. 43, pp. 137-146, 2017
- [30] Morano P., Tajani F., Torre C. M.: *Artificial intelligence in property valuations: An application of artificial neural networks to housing appraisal*. In: Advances in Environmental Science and Energy Planning, pp. 23 - 29, 2015
- [31] Četković J., Lakić S., Lazarevska M., Žarković M., Vujošević S., Cvijović J., Gogić M.: *Assessment of the Real Estate Market Value in the European Market by Artificial Neural Networks Application*. In: Complexity, 2018
- [32] Kitapci O., Tosun Ö., Tuna M., Türk T.: *The Use of Artificial Neural Networks (ANN) in Forecasting Housing Prices in Ankara, Turkey*. In: Journal of Marketing and Consumer Behaviour in Emerging Markets vol. 1, n. 5, pp. 4 - 14, 2017
- [33] Abidoye R. B., Chan A. P. C., Abidoye F. A., Oshodi O. S.: *Predicting property price index using artificial intelligence techniques: evidence from Hong Kong*. In: International Journal of Housing Markets and Analysis vol. 12, n. 6, pp. 1072 - 1092, 2019
- [34] Ho W. K. O., Tang B., Wong S. W.: *Predicting property prices with machine learning algorithms*. In: Journal of Property Research, n. 3, vol. 1, pp. 48 - 70, 2020
- [35] Chiarazzo V., Caggiani L., Marinelli M., Ottomanelli M.: *A Neural Network based Model for Real Estate Price Estimation Considering Environmental Quality of Property Location*. In: Transportation Research Procedia n. 3, pp. 810 - 817, 2014
- [36] Liang L., Wu D.: *An application of pattern recognition on scoring Chinese corporations financial conditions based on back propagation neural network*. In: Computers and Operational Research vol. 32, n. 5, pp. 1115 - 1129, 2005

