

CORSO DI LAUREA MAGISTRALE IN INGEGNERIA GESTIONALE

UNIVERSITA' POLITECNICA DELLE MARCHE - SEDE DI FERMO



**“METODI DI PREVISIONE DELLA DOMANDA COME INPUT PER
APPLICAZIONI MRP: IL CASO SANTONI”**

**“DEMAND FORECAST METHODS AS INPUT FOR MRP APPLICATIONS: THE
SANTONI CASE”**

CANDIDATO: Andrea De Flaviis (matr. 1093727)

RELATORE: Ch.mo Prof. Filippo Emanuele Ciarapica

ANNO ACCADEMICO 2020 - 2021

INDICE

PREMESSA	PAG.2
Cap.1 - Metodi di previsione della domanda	PAG.3
1.1 – L'Importanza delle previsioni della domanda nelle applicazioni MRP	PAG.3
1.2 - I principali metodi di previsione della domanda: metodi quantitativi e metodi qualitativi	PAG.5
1.3 – Tecniche qualitative di previsione della domanda	PAG.9
1.4 - Tecniche quantitative di previsione della domanda: i metodi statici	PAG.10
1.5 - Tecniche quantitative di previsione della domanda: i metodi adattivi	PAG.20
1.6 - Tecniche di machine learning nelle previsioni di domanda: reti neurali multistrato (MPL) non ricorrenti e ricorrenti	PAG.30
1.7 - Previsioni di domanda in ambiente incerto e il metodo Monte Carlo	PAG.42
1.8 - Gli errori nel processo di previsione di domanda	PAG.48
1.9 – Conclusioni	PAG.51
Cap.2 - L'azienda Santoni S.p.a	PAG.52
2.1 – Panoramica dell'azienda	PAG.52
Cap.3 - I metodi di previsione di domanda applicati al caso Santoni	PAG.54
3.1 – Introduzione	PAG.54
3.2 – Previsioni dei sottopiedi (SP)	PAG.55
3.3 – Previsioni dei fondi (FD)	PAG.61
3.4 – Previsioni dei tacchi alti (TA)	PAG.67
3.5 – Previsioni dei tacchi bassi (TB)	PAG.74
3.6 – Previsioni degli inserti (IS)	PAG.80
CONSIDERAZIONI FINALI	PAG.85
APPENDICE, BIBLIOGRAFIA E SITOGRAFIA	PAG.86
RINGRAZIAMENTI	PAG.89

PREMESSA

Questo lavoro di tesi ha l'obiettivo di applicare i principali metodi di previsione della domanda utilizzabili per individuare gli input dei piani MRP ad un caso reale: quello dell'azienda Santoni S.p.a, un'azienda del settore calzaturiero.

Inizialmente, nel primo capitolo si accennerà brevemente a che cosa siano i piani MRP e all'importanza delle previsioni di domanda per la loro stesura.

In seguito, si introdurrà la distinzione tra metodi di previsione della domanda di tipo qualitativo e di tipo quantitativo, vedendo i vari vantaggi e svantaggi, i vari casi in cui sia conveniente utilizzare i primi e quelli in cui sia conveniente utilizzare i secondi.

Si dunque elencheranno e descriveranno i principali metodi di tipo qualitativo per poi approfondire nel dettaglio i metodi di tipo quantitativo. Verrà infatti riportata la distinzione esistente tra i vari metodi quantitativi: metodi statici, metodi adattativi, metodi basati sul machine learning (in particolare si parlerà molto delle reti neurali) e metodi basati sulla statistica e le simulazioni. Si quindi spiegheranno le varie situazioni in cui si utilizzano i diversi tipi di metodi quantitativi.

Infine, l'ultima parte del primo capitolo è dedicata ai vari indicatori che servono a valutare le performances di un metodo di previsione di domanda (errore medio, errore quadratico medio, etc.)

Invece, nel Secondo capitolo si introdurrà brevemente l'azienda Santoni spiegando brevemente il processo produttivo e elencando i componenti oggetto delle previsioni di domanda (le previsioni di domanda hanno come obiettivo quello di fare capire all'azienda quanti componenti ordinare visto che i prodotti vengono gestiti su commessa ma i componenti vengono gestiti a scorta).

Per finire, nel terzo capitolo si dunque applicheranno alcuni dei metodi quantitativi elencati ai componenti e si cercherà di capire componente per componente quale sia il metodo migliore. Infine, si proverà a individuare quale si rivelerà complessivamente il metodo più efficace osservando non solo gli indicatori ma anche vedendo se data la complessità del metodo convenga o meno puntarci (un metodo può essere molto performante ma troppo complesso da implementare).

CAPITOLO 1

METODI DI PREVISIONE DELLA DOMANDA

1.1 - L'IMPORTANZA DELLE PREVISIONI DELLA DOMANDA NELLE APPLICAZIONI

MRP

Nel processo di pianificazione della produzione una parte fondamentale è quella della previsione della domanda poiché essa rappresenta l'input di tutti i vari piani di produzione. Le previsioni di domanda sono particolarmente importanti nelle produzioni di tipo **PUSH** ma anche (seppur con importanza minore) nelle produzioni di tipo **PULL** (produzioni come il JUST IN TIME che mirano a produrre cercando di ridurre la giacenza iniziando la produzione solo con un ordine effettivo del cliente). Le produzioni di tipo PUSH hanno come obiettivo quello di produrre cercando di "anticipare" la domanda del cliente facendo delle stime di domanda e producendo sulle base delle stesse. Una tipica produzione PUSH nel settore manifatturiero è quella basata sui piani MRP (Materials Requirements Planning): si usano le domande stimate per realizzare il piano principale di produzione (Master Production Schedule o **MPS** (figura 1)) e poi si utilizzano i lead time (tempi di lavorazione, assemblaggio, approvvigionamento), le distinte base e le informazioni sulla giacenza per completare l'MPS e redigere i piani MRP.

PERIODO	1	2	3	4	5
DOMANDA	10	20	5	6	10
FABBISOGNO NETTO	-10	-10	-5	1	10
EMISSIONE ORDINI		1	10		
ARRIVI ORDINI				1	10
MAGAZZINO FINALE	30	10	5	0	0
LEAD TIME DI ASSEMBLAGGIO	2 PERIODI				
MAGAZZINO INIZIALE	40				

Figura 1: ESEMPIO MPS

Nell'esempio raffigurato sopra si emettono gli ordini di assemblaggio/ fabbricazione due periodi in anticipo poiché il prodotto fittizio preso in considerazione (che verrà chiamato prodotto x) impiega due settimane per essere completato. Una volta redatto l'MPS si poi passa ai vari piani MRP (figura 3), ovvero i piani di approvvigionamento dei componenti necessari a realizzare il prodotto. Nel

realizzare quest'ultimi si prende in considerazione la **distinta base (BOM)** del prodotto in questione (figura 2) oltre ai lead time di produzione/approvvigionamento dei componenti (a seconda se i componenti vengano o meno prodotti internamente oppure forniti da terzi). La BOM è invece un documento che contiene tutte le informazioni sui componenti necessari per realizzare un determinato prodotto (quantità, nome, etc.)

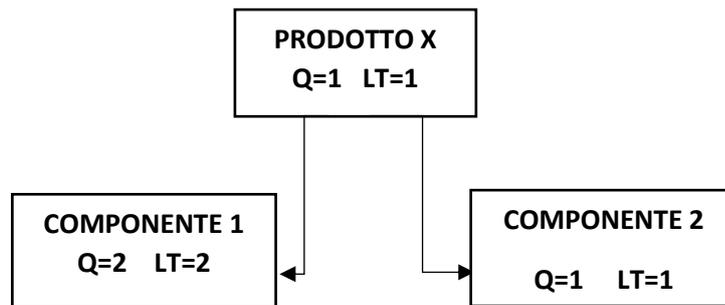


Figura 2: ESEMPIO BOM

PERIODO	1	2	3	4	5
DOMANDA	0	2	20	0	0
FABBISOGNO NETTO	-10	-8	12	0	0
EMISSIONE ORDINI	12				
ARRIVI ORDINI			12		
MAGAZZINO FINALE	10	8	0	0	0
LEAD TIME DI APPROVVIGIONAMENTO	2 PERIODI				
MAGAZZINO INIZIALE	10				

Figura 3: ESEMPIO MRP

L'esempio sopra è relativo al componente "1" del prodotto "x". Si noti come la domanda corrisponda alla riga "emissione ordini" dell'MPS moltiplicata per due (per produrre una quantità di prodotto x c'è bisogno di due componenti "1" e ciò è noto dalla BOM). In sostanza, si deve fare in modo che tutti i componenti arrivino in tempo per l'inizio della produzione.

Da questi brevi cenni su cosa siano i sistemi MRP si può capire l'importanza che riveste la previsione di domanda in quest'ultimi. Infatti, una sottostima di domanda può portare a una perdita di clienti potenziali (mancati guadagni) mentre una sovrastima della stessa può portare a un riempimento indesiderato del magazzino. Quest'ultima situazione è da evitare tanto quanto la prima poiché la giacenza rappresenta un capitale immobilizzato che non sta venendo sfruttato oltre a generare costi di mantenimento a scorta (luce, assicurazione, personale di magazzino, etc.)

Le sottostime e le sovrastime di domanda possono essere contenute migliorando il sistema previsionale e utilizzando magari **metodi di tipo adattivo** (vedere capitolo 1.5), i quali sfruttano una caratteristica dell'MRP che è quella dell'**orizzonte mobile**. Quest'ultimo è semplicemente un aggiornamento periodico dei piani MPS/MRP e la frequenza di aggiornamento degli stessi dipende dalle scelte aziendali. L'MRP/MPS infatti è caratterizzato da un **orizzonte temporale** ben definito (il numero di periodi) che può però essere "shiftato" in avanti in modo da tenere conto della situazione in continua evoluzione (cambiamento nei dati di domanda, lead time, etc.) Tornando all'esempio del prodotto "x", si potrebbe ipotizzare di avere un orizzonte mobile di 2 periodi e di aggiornare i piani di produzione ogni 2 periodi. In questo modo, all'inizio del periodo 3 avremo i dati reali di domanda nei periodi 1 e 2 oltre a eventuali informazioni su cambiamenti nei lead time, etc. Oltre a tutto ciò, si potrebbe anche iniziare a effettuare previsioni di domanda per i periodi 6 e 7 (poiché l'orizzonte temporale considerato nell'esempio è di 5 periodi e i periodi ora sono 3, 4, 5, 6 e 7) considerando però ora anche i nuovi dati a disposizione nell'effettuare le previsioni. Ovviamente, andranno aggiornati anche gli ordini programmati e le giacenze previste ma tutti gli ordini già precedentemente partiti rimarranno immutati (a meno che i fornitori non accettino diversamente). L'utilizzo di un orizzonte mobile si sposa molto bene con le previsioni adattative poiché, come si vedrà tra poco, esse aggiornano i loro parametri sulla base del confronto tra dati di domanda reali e dati di domanda previsti.

Infine, è opportuno dire che vi sono anche sistemi **misti** combinano le due logiche di produzione (PUSH e PULL). Ad esempio, i prodotti vengono venduti su commessa ma vengono comunque redatti gli MRP (solo i componenti vengono gestiti a scorta). In questo caso, **le previsioni di domanda vengono dunque effettuate non sui prodotti ma sui componenti tenendo magari in considerazione il tipo di prodotto che li utilizza**. L'azienda oggetto di questa tesi (la **Santoni S.p.a**) utilizza proprio un sistema di questo tipo.

1.2 - I PRINCIPALI METODI DI PREVISIONE DELLA DOMANDA: METODI QUANTITATIVI E METODI QUALITATIVI

Nell'effettuare previsioni di domanda possono essere adottati due approcci essenzialmente opposti: quello **quantitativo** e quello **qualitativo**. Il primo si basa essenzialmente su metodi matematici che mirano ad analizzare i dati a disposizione al fine di ricavare una previsione della domanda futura. Il secondo approccio è invece meno strutturato e si basa prevalentemente sulle

opinioni di esperti. L'approccio quantitativo è senza dubbio molto efficace nel caso in cui si abbia a che fare con ambienti stabili (non vi sono troppe variabili incontrollabili) e con orizzonti temporali non eccessivamente lunghi (al massimo un 2/3 anni). L'approccio qualitativo è invece indicato in tutte le situazioni opposte alla precedente: un ambiente fortemente instabile (forte instabilità politica/economica, concorrenti con comportamenti imprevedibili, ...) e orizzonti temporali lunghi.

Le principali tecniche quantitative sono:

- **analisi delle serie temporali con metodi di tipo statico;**
- **analisi delle serie temporali con tecniche di tipo adattativo;**
- **tecniche di machine learning: reti neurali multistrato (MPL) non ricorrenti e ricorrenti;**
- **tecniche statistiche e simulazioni (come quelle effettuabili con il metodo Monte Carlo).**

Invece, le principali tecniche di tipo qualitativo sono:

- **metodo Delphi;**
- **opinioni di esperti (brainstorming e simili).**

In generale, a prescindere dal tipo di approccio che verrà poi scelto, prima di poter iniziare a effettuare le previsioni di domanda è molto importante analizzare alcuni fattori come:

- **il tipo di mercato e di prodotto (o assieme/gruppo di prodotto) presi in considerazione;**
- **la concorrenza;**
- **l'ambiente politico ed economico;**
- **l'ambiente culturale;**
- **l'orizzonte di previsione.**

Sono infatti questi fattori che determineranno poi la scelta del tipo di tecnica utilizzare (se una qualitativa o una quantitativa) sulla base delle considerazioni fatte precedentemente. Prima di procedere oltre si andranno brevemente ad analizzare i fattori sopra menzionati per capire la loro importanza.

IL TIPO DI MERCATO, DI PRODOTTO (O ASSIEME/GRUPPO DI PRODOTTO) E LA CONCORRENZA

Il tipo di prodotto oggetto delle previsioni di domanda (o il prodotto di cui il componente oggetto della previsione fa parte) e il suo mercato sono molto importanti poiché un prodotto di prima necessità o di largo consumo (e un suo componente) avrà probabilmente una domanda più stabile rispetto a un prodotto ad alta tecnologia come uno smartphone. Nel caso di prodotti di prima necessità e di largo consumo una delle poche variabili che potrebbe essere incontrollabile è quella della concorrenza; ipotizzando però che in questo caso si abbia un mercato simile al tipo “concorrenza perfetta” (essendo i beni sostitutivi offerti dai concorrenti perfettamente equivalenti al proprio) essa non dovrebbe compiere azioni troppo imprevedibili (al contrario, nel caso di uno smartphone o di un bene ad alta innovazione tecnologica si ha che la concorrenza può agire in modo completamente imprevedibile sviluppando ad esempio un nuovo modello di smartphone con caratteristiche completamente diverse da quello venduto dalla propria azienda e magari persino più gradito al mercato). Le stesse considerazioni fatte precedentemente valgono ovviamente anche per altri tipi di beni non necessariamente “high tech” come automobili, giocattoli, etc. Infine, si può anche dire che i prodotti non a largo consumo e di prima necessità hanno un certo andamento temporale rispetto alle vendite: inizialmente le vendite aumentano in maniera quasi esponenziale (fase di introduzione) per poi iniziare a rallentare nella fase di crescita, stabilizzarsi nella fase di maturità e crollare nella fase di declino (figura 4).

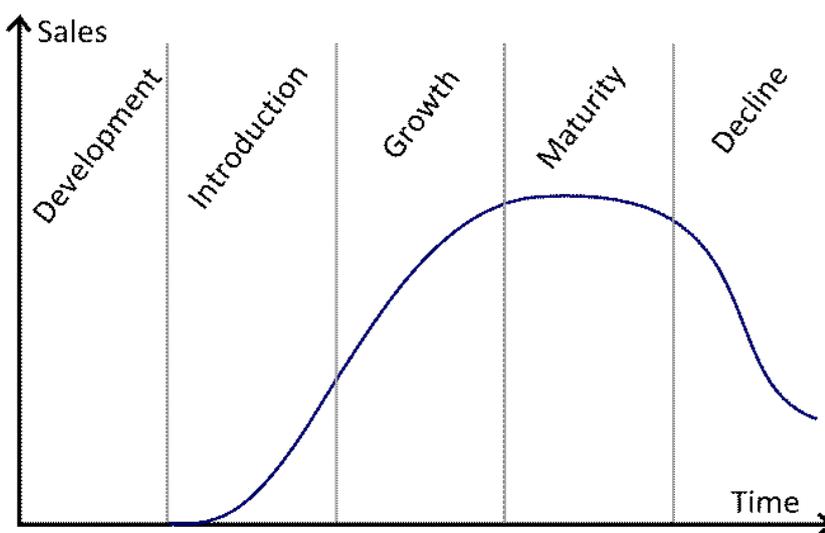


Figura 4: CICLO DI VITA DEL PRODOTTO

Per fare un esempio, si potrebbe considerare il vecchio telefono cellulare a tasti: egli è tuttora nella fase di declino a causa degli smartphone.

In generale, si potrebbe dunque concludere tutto questo discorso dicendo che per prodotti più di largo consumo/prima necessità sarebbe più facile utilizzare tecniche di tipo quantitativo rispetto agli altri tipi di prodotti (come quelli ad alta tecnologia) dicendo però che nel caso si abbia a che fare con quest'ultimi bisogna considerare il loro stato nel ciclo di vita: si ha più instabilità durante la fase di crescita (si potrebbero usare tecniche qualitative miste a quantitative) e meno instabilità nella fase di maturità (qui si possono utilizzare facilmente tecniche quantitative).

In alternativa a fare previsioni per singoli prodotti si possono anche effettuare le previsioni di domanda per assiemi o gruppi di prodotti (aggregando quindi prodotti diversi). Ovviamente, le previsioni andranno disaggregate per singoli prodotti e inoltre, se l'aggregazione dovesse essere fatta per prodotti che abbiano un andamento di domanda troppo diverso si avrebbe un certo errore sulle previsioni dei singoli prodotti. Proprio per questo, l'aggregazione è molto consigliata nel caso si avessero prodotti molto simili (ad esempio diverse linee di frigoriferi in cui l'unica cosa differente è il colore). Comunque, se fatta bene l'aggregazione può rendere più semplice effettuare previsioni di domanda.

L'AMBIENTE POLITICO, SOCIALE E CULTURALE

Il tipo di ambiente in cui si opera è molto importante e può influenzare molto le previsioni di domanda. Infatti, un ambiente politico molto instabile come nel caso di paesi in cui vi è un forte rischio di colpi di stato potrebbe dar luogo a problemi nell'operare con un'azienda nel paese stesso. Bisogna inoltre tenere conto dell'ambiente sociale e di quello culturale (nessuno scommetterebbe su un forte aumento della domanda di carne di maiale in paese a maggioranza islamica). Ovviamente, come già detto in precedenza, un ambiente instabile incita all'utilizzo di metodi di tipo qualitativo.

ORIZZONTE DI PREVISIONE

Per l'orizzonte di previsione valgono le considerazioni già effettuate parlando dei metodi quantitativi e qualitativi: aumentando l'orizzonte di previsione si fanno previsioni per periodi temporali molto lunghi e l'errore previsionale può essere molto elevato. Di conseguenza, in questi casi convergono i metodi qualitativi. Ovviamente, oltre all'orizzonte di previsione è anche importante scegliere come suddividere quest'ultimo (**periodi**). Infatti, possiamo effettuare

previsioni prendendo come orizzonte di previsione n periodi che possono essere a loro volta settimane, trimestri, etc.

Analizzando tutti gli elementi sopra riportati si può dunque capire se convenga o meno un approccio piuttosto che l'altro.

1.3 - TECNICHE QUALITATIVE DI PREVISIONE DELLA DOMANDA

Adesso, verranno elencate e spiegate brevemente le principali tecniche qualitative di previsione di domanda accennate in quello precedente.

OPINIONI DI ESPERTI

La più comune tecnica qualitativa è ovviamente quella che si basa sull'opinione di esperti: questi andranno a effettuare le previsioni guardando la concorrenza, il mercato, la situazione politica, etc. Un esempio di opinione di esperti è: "Il concorrente x ha lanciato un nuovo prodotto innovativo. Prevedo che a causa di ciò la domanda del prossimo mese potrebbe abbassarsi del 30%". Le opinioni espresse possono esserlo durante sessioni di brainstorming (letteralmente "tempesta di cervelli"): le idee di un team di esperti vengono espresse liberamente e registrate per iscritto mentre un moderatore si occupa di fare in modo che tutti riescano a parlare e che la discussione sia proficua. Una volta terminata la sessione di brainstorming verranno messe ai voti le varie idee e si sceglierà quella vincente.

METODO DELPHI

Questo metodo mira a dare un approccio più strutturato al caso in cui si utilizzino le opinioni di esperti per effettuare le previsioni di domanda. Esso nacque durante le prime fasi della Guerra Fredda e si basa essenzialmente sul far convergere varie opinioni in una unica. Nell'applicare questo metodo risulta molto importante la figura del "facilitator", ovvero colui che somministra una serie di questionari ai vari esperti che hanno il compito di rispondere ai suddetti dando così la loro opinione. Dopo che i questionari sono stati completati in un tempo prestabilito, essi vengono commentati dai vari partecipanti in modo che ognuno esprima un parere su ciò che pensano gli altri. I vari pareri vengono poi analizzati e si riparte con un'altra somministrazione di questionari

ripetendo il processo fino a raggiungere un'opinione condivisa. La forza di questo metodo è l'**anonimato dei partecipanti** che fa sì che le personalità dominanti non emergano influenzando così gli altri.

1.4 - TECNICHE QUANTITATIVE DI PREVISIONE DELLA DOMANDA: I METODI STATICI

Un metodo quantitativo di previsione della domanda è detto **statico** quando i parametri del metodo non vengono aggiornati considerando i dati reali di domanda man mano che il tempo avanza.

PREVISIONI QUANTITATIVE: LE COMPONENTI DELLA DOMANDA

Ogni curva che mostra l'andamento della domanda rispetto al tempo ha due componenti principali: una **casuale** e una **sistematica**. La prima, come dice il nome stesso, è imprevedibile e l'ideale sarebbe avere una curva che abbia un'incidenza ridotta della componente casuale rispetto alla sistematica. Nel caso la domanda avesse una componente casuale prominente si potrebbero utilizzare tecniche **qualitative** oppure tecniche statistiche e simulazioni come quella del metodo Monte Carlo. La seconda componente, la sistematica, è invece più facilmente prevedibile ed è composta a sua volta da una parte di **trend** (esso può essere lineare e del tipo " $L+m*t$ " dove L è la **componente di livello**, t è il tempo, m un coefficiente angolare e $m*t$ è dunque la **tendenza**) e da una **oscillatoria**. A sua volta, la componente oscillatoria è composta da una parte **ciclica** e da una **stagionale**. Il trend indica la tendenza generale della domanda (aumento o diminuzione) mentre la parte oscillatoria è dovuta da variazioni stagionali della domanda per quanto riguarda la parte stagionale (ad esempio d'inverno le vendite di cappotti subiscono un'impennata mentre d'estate vanno praticamente quasi ad azzerarsi) e da variazioni legate al ciclo economico (stato dell'economia) per quanto riguarda la componente ciclica (periodi di crisi economica fanno ridurre la domanda). Ovviamente, le oscillazioni dovute alla stagionalità sono più marcate rispetto a quelle dovute alla ciclicità (figura 5).

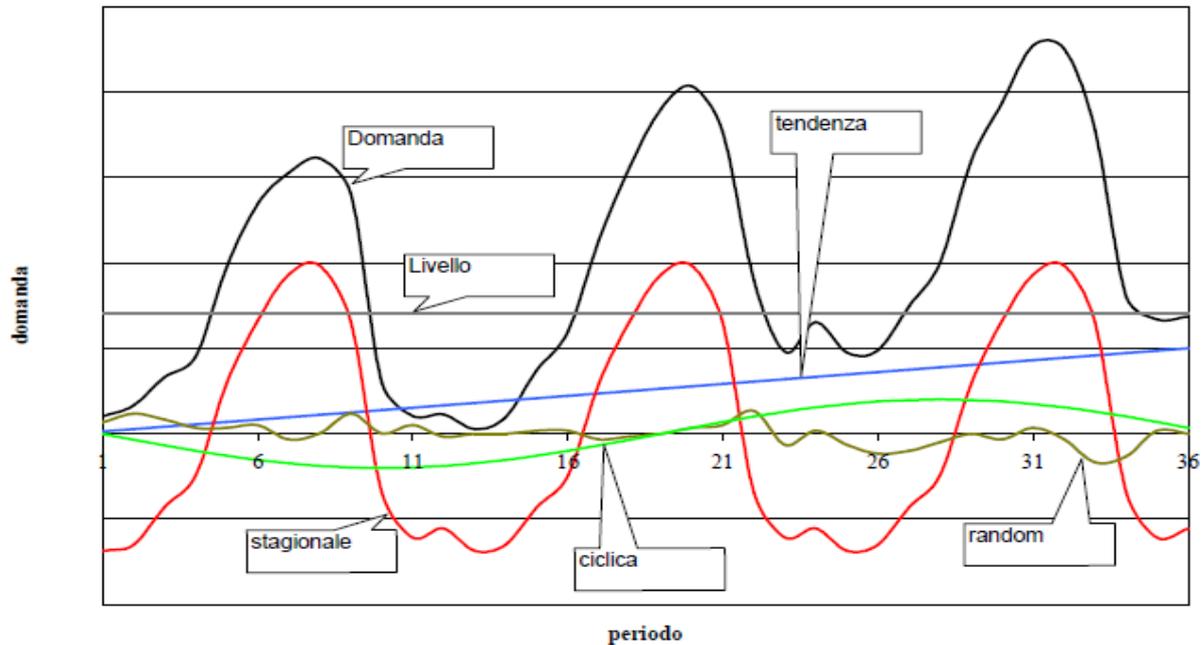


Figura 5: COMPONENTI DELLA DOMANDA (CON UN TREND DI TIPO LINEARE)

I TIPI DI MODELLI UTILIZZABILI: ADDITIVO, MOLTIPLICATIVO E MISTO

Nell'effettuare previsioni di domanda con metodi di tipo statico che sfruttano le cosiddette **serie storiche** (come input vengono utilizzati i dati storici relativi alla domanda) si possono utilizzare 3 modelli per rappresentare la previsione: additivo, moltiplicativo e misto. Si premette che da ora in poi verranno ignorate la componente casuale della domanda (si può prevedere solamente quella sistematica utilizzando metodi non basati sulle simulazioni) e quella ciclica (visto che produce oscillazioni di ampiezza ridotta rispetto alle oscillazioni stagionali).

1. MODELLO ADDITIVO:

$$\text{DOMANDA} = \text{LIVELLO} + \text{TENDENZA} + \text{COMPONENTE STAGIONALE}$$

2. MODELLO MOLTIPLICATIVO:

$$\text{DOMANDA} = \text{LIVELLO} * \text{TENDENZA} * \text{COMPONENTE STAGIONALE}$$

3. MODELLO MISTO:

$$\text{DOMANDA} = (\text{LIVELLO} + \text{TENDENZA}) * \text{COMPONENTE STAGIONALE}$$

D'ora in poi verrà utilizzato prevalentemente un modello di tipo **misto**.

NB: se la domanda non dovesse presentare stagionalità le componenti stagionali possono essere ignorate e si considera solamente la parte di trend della domanda (si utilizza una semplice regressione).

IL PROCESSO DI DESTAGIONALIZZAZIONE DELLA DOMANDA

L'unico metodo statico che si verrà analizzato è basato generalmente sulla **destagionalizzazione della domanda** (se la domanda **non è stagionale** non è però necessaria come fatto notare precedentemente). Questo processo è fondamentale in caso di variazioni stagionali perché permette poi di poter sfruttare le **regressioni** per individuare i trend. In poche parole, destagionalizzare la domanda significa depurarla completamente dalle oscillazioni dovute alla stagionalità facendo in modo che i dati storici di domanda a disposizione si dispongano seguendo il più possibile un particolare trend.

La prima cosa da fare durante il processo di destagionalizzazione è individuare la **periodicità "P"** della domanda ovvero il numero di stagioni che si hanno in un determinato orizzonte temporale (in genere anno). Si potrebbero avere ad esempio 4 stagioni in un anno: invernale, primaverile, estiva e autunnale. Ogni stagione dà luogo a un'oscillazione della curva di domanda. Una volta individuato P si calcola la domanda destagionalizzata \bar{D}_t a partire dalla domanda stagionalizzata D_t .

Le formule da utilizzare per ogni periodo t sono le seguenti:

$$\bar{D}_t = \begin{cases} \left(D_{t-p/2} + D_{t+p/2} + \sum_{i=t+1-p/2}^{t-1+p/2} 2 \cdot D_t \right) / (2 \cdot p) & \text{per } p \text{ pari} \\ \sum_{i=t+1-p/2}^{t-1-p/2} D_t / p & \text{per } p \text{ dispari} \end{cases}$$

t rappresenta il tempo e parte da uno per indicare il primo periodo. D_1 indica dunque la domanda del primo periodo.

Applicando queste formule ai dati storici a disposizione si hanno ora i **dati di domanda destagionalizzati** che possono essere utilizzati per trovare il trend.

I TIPI DI TREND

1 – TREND DI TIPO LINEARE

Un trend di tipo lineare è rappresentato dall'equazione della retta: $Y(t) = L + m * t$ dove **L** è la già citata **componente di livello**, **Y** è la **variabile dipendente** mentre **t** è la **variabile indipendente** e **m** è il coefficiente angolare. Per individuare un trend di tipo lineare in genere si sfrutta la **regressione lineare**: un processo matematico che permette di trovare una relazione lineare tra 2 variabili (dipendente e indipendente). La regressione viene ovviamente fatta sui dati destagionalizzati della domanda.

IL PROCESSO DI REGRESSIONE LINEARE

Si vuole trovare una retta del tipo descritto precedentemente che approssimi la relazione esistente tra l'i-esima variabile dipendente e l'i-esima variabile indipendente cercando di minimizzare l'errore quadratico totale, ovvero la relazione: $S(L,m) = \sum_{i=1}^N (Y_i - L - m * t_i)^2$ dove N rappresenta il numero di variabili dipendenti (che è uguale a quello di variabili indipendenti). Derivando dunque rispetto alle variabili "L" e "m" (ovvero i parametri incogniti della retta di regressione) e uguagliando le derivate a zero (punto di minimo) si ottiene:

$$\frac{\partial S}{\partial L} = -2 * \sum_{i=1}^N (Y_i - L - m * t_i) = 0$$

$$\frac{\partial S}{\partial m} = -2 * \sum_{i=1}^N (Y_i - L - m * t_i) * t_i = 0$$

$$L = \frac{\sum Y_i}{N} - m * \frac{\sum t_i}{N} \qquad m = \frac{N * \sum t_i * Y_i - \sum t_i * \sum Y_i}{N * \sum t_i^2 - (\sum t_i)^2}$$

Si sono dunque trovati i parametri della retta di regressione (figura 6).

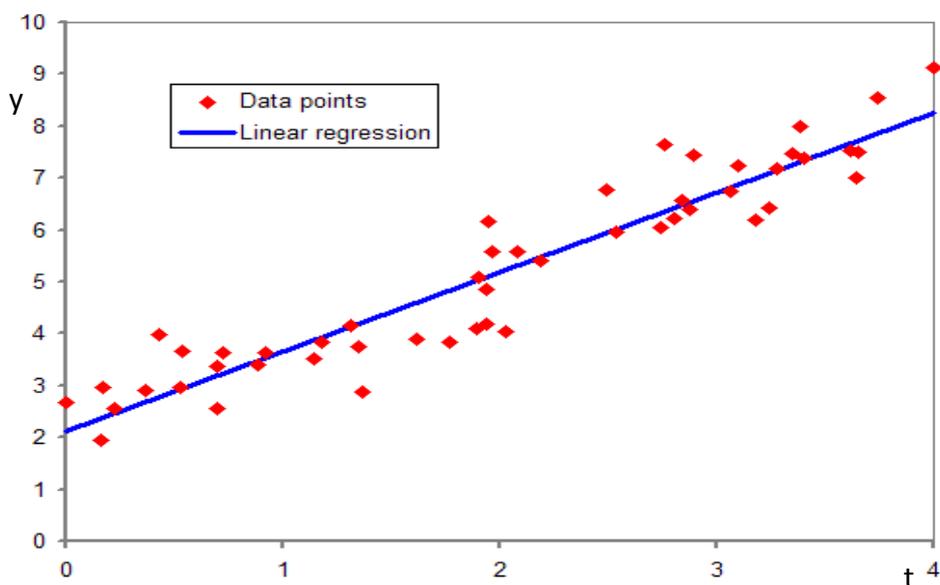


Figura 6: ESEMPIO DI REGRESSIONE LINEARE

2 – TREND DI TIPO LOGARITMICO E ESPONENZIALE

Nel caso si notasse che il trend seguito dalla domanda destagionalizzata è diverso dal lineare potremmo optare per altri tipi di regressione non lineare come la **logaritmica** (figura 7) o l'**esponenziale** (figura 8). Nel primo caso avremo una curva del tipo: $Y(t)=L+m*\ln(t)$ dove t è la variabile **dipendente**, Y l'indipendente e L la **componente di livello**. Nel secondo caso si avrebbe invece una curva del tipo: $y(t) = L * e^{m*t}$. La curva esponenziale si può linearizzare applicando il logaritmo e ottenendo: $\ln(Y(t)) = \ln(L)+t*m$. **NB: ln è il logaritmo naturale**

In entrambi casi si possono comunque applicare le stesse formule della regressione lineare ma sostituendo t con $\ln(t)$ nelle formule della regressione lineare nel caso logaritmico e sostituendo $\ln(Y(t))$ nelle formule della regressione lineare nel caso esponenziale. Ovviamente, nel caso della regressione esponenziale si ricaverebbe non L ma $\ln(L)$ e basterà dunque applicare l'esponenziale per ricavarlo.

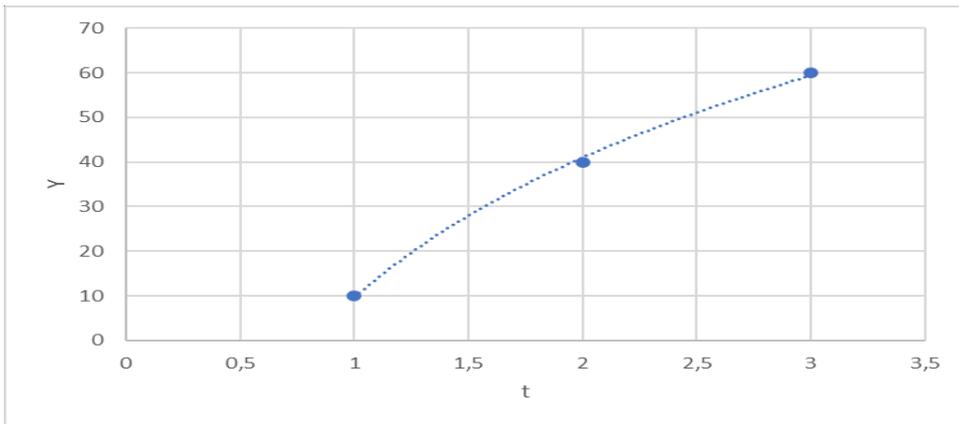


Figura 7: ESEMPIO DI REGRESSIONE LOGARITMICA

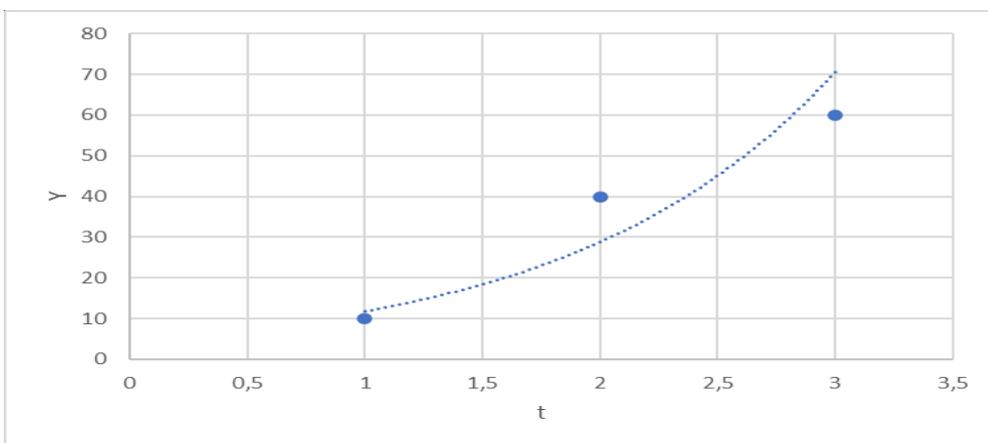


Figura 8: ESEMPIO DI REGRESSIONE ESPONENZIALE

La regressione esponenziale rappresenta un caso interessante poiché non facendo uso di una funzione lineare il fattore di livello moltiplica un esponenziale e implicitamente quindi si usa un **modello moltiplicativo**: livello (L)*tendenza (e^{m*t})*componente stagionale.

3 – TREND DI TIPO LOGISTICO

L'ultimo trend che verrà ora citato è quello di tipo **logistico**. Questo tipo di trend è molto indicato nel caso la previsione avesse come obiettivo quello di stimare la domanda a lungo termine specialmente in caso si avesse a che fare con prodotti la cui domanda segue **il ciclo di vita del**

prodotto (vedere capitolo 1.2). Infatti, la curva logistica ha un andamento inizialmente esponenziale che poi tende a smorzarsi fino a diventare una retta parallela all'asse delle ascisse. Si può dunque facilmente intuire come la fase esponenziale rappresenti la fase di introduzione e di crescita mentre quella "piatta" rappresenti la fase di maturità. L'equazione della curva logistica venne definita dal matematico belga **Verhulst** allo scopo di studiare la dinamica delle popolazioni che vivono in un ambiente con risorse limitate (la popolazione ha dunque una crescita massima). L'equazione logistica si ottiene risolvendo l'equazione differenziale:

$$Y'(t) = m * Y(t) * \left(1 - \frac{Y(t)}{K}\right)$$

$Y(t)$ è la domanda all'istante t , m è il tasso di crescita della domanda e k è la domanda massima ottenibile (prodotto in fase di maturità).

Risolvendo l'equazione differenziale sopra riportata e ponendo $Y(0) = L$ si ottiene:

$$Y(t) = \frac{K * L * e^{m*t}}{k + L * (e^{m*t} - 1)}$$

Graficando l'equazione precedentemente riportata si ottiene un grafico simile a questo (figura 9):

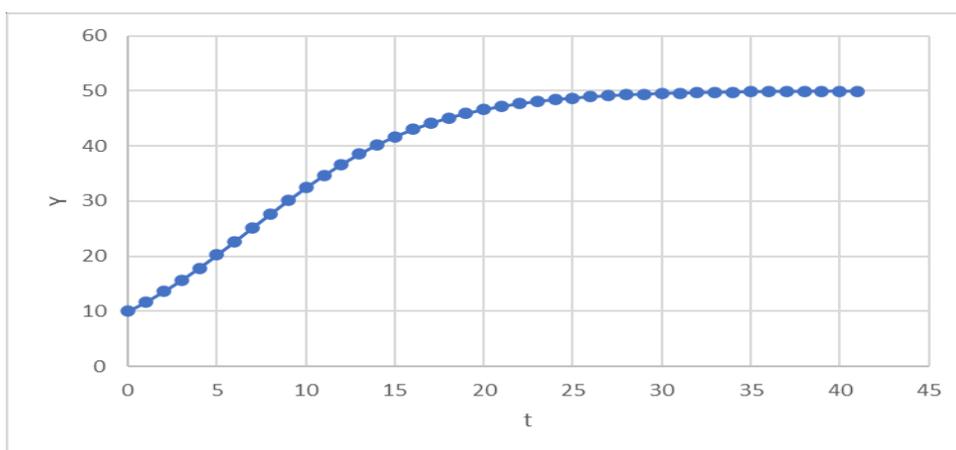


Figura 9: ESEMPIO DI REGRESSIONE LOGISTICA

Nell'esempio riportato si è posto $m=0,2$, $K=50$ e $L=10$.

La proprietà più importante della curva logistica è questa: $\lim_{t \rightarrow +\infty} Y(t) = K$. Infatti, si sa che la curva logistica tenderà ad appiattirsi sempre di più fino ad assumere un andamento piatto che avrà un valore coincidente a quello della domanda massima. Lavorando con la logistica si dovrà però conoscere sia il tasso di crescita della domanda (più sarà elevato più velocemente la domanda tenderà a stabilizzarsi vicino a K), sia la componente di livello e sia la domanda potenziale massima. I vari parametri possono essere intuiti osservando i dati storici e vedendo il comportamento della domanda nel tempo (oppure si utilizzano strumenti informatici di fitting come quello di Matlab).

Un'ultima cosa molto importante da dire è che utilizzando un trend logistico non si userà né un modello additivo né uno moltiplicativo né uno misto. Si userà infatti un modello del tipo:

DOMANDA = TREND LOGISTICO*COMPONENTE STAGIONALE.

CALCOLO DEI FATTORI STAGIONALI

Una volta terminato il calcolo del trend dovremmo avere una situazione come quella rappresentata nella figura 10 (esempio fatto considerando un trend lineare).

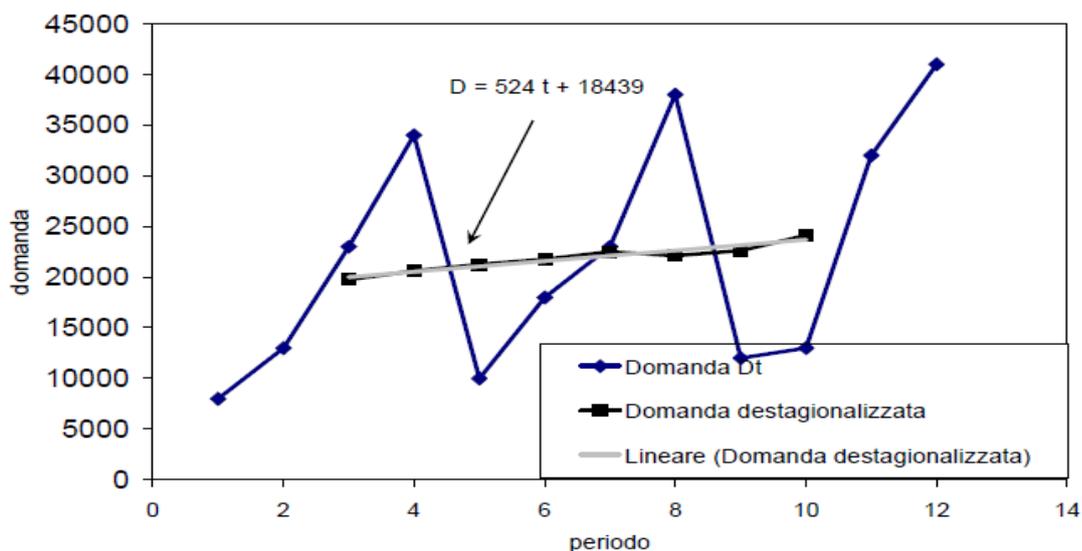


Figura 10: ESEMPIO DI DOMANDA DESTAGIONALIZZATA

Il prossimo passo da effettuare per terminare le previsioni di domanda con un modello di tipo statico è quello del calcolo dei **fattori stagionali**.

Per prima cosa si calcolano i **fattori stagionali per ogni periodo** che sono definiti in questo modo:

$$S_t = D_t / \overline{D}_t$$

S_t è il fattore stagionale relativo al periodo t-esimo, D_t è la domanda non destagionalizzata t-esima mentre \overline{D}_t è la domanda destagionalizzata t-esima calcolata individuando il trend (si guarda la curva ottenuta con uno dei tipi di regressione elencati precedentemente). Una volta calcolati i fattori stagionali per ogni periodo si possono finalmente trovare i fattori stagionali per ogni stagione facendo semplicemente la media dei fattori stagionali di periodo relativi a una singola stagione. Ad esempio, avendo 3 anni con 4 stagioni ciascuno avremo tre fattori stagionali di periodo per ciascuna stagione e per trovare il fattore stagionale relativo alla stagione è sufficiente sommarli e dividerli per tre. Questa operazione va ovviamente ripetuta quattro volte (una volta per stagione).

Matematicamente si ha:

$$S_i = \sum_{j=0}^{r-1} \frac{S_{j*p+i}}{r}$$

S_i rappresenta il fattore stagionale relativo alla stagione i-esima, p il numero di stagioni in un orizzonte temporale (periodicità), r il numero di cicli stagionali (quante volte si ripete la stagione e che nell'esempio precedente era tre) mentre il numeratore rappresenta il fattore stagionale di periodo.

TERMINE DEL PROCESSO PREVISIONALE

Calcolati tutti i fattori stagionali si può finalmente effettuare la previsione di domanda. Se si utilizzasse un **modello misto** e un trend lineare (figura 11) si avrebbe:

$$F_t = (L + m * t) * S_t$$

F_t è la previsione di domanda relativa al periodo t , $L + m * t$ è la retta di regressione mentre S_t è il fattore stagionale relativo alla stagione in cui è situato il periodo t -esimo (si vede a quale fattore stagionale S_i corrisponde il periodo t).

Con un modello misto e un **trend logaritmico** si avrebbe:

$$F_t = (L + m * \ln(t)) * S_t$$

Con un **trend esponenziale** si avrebbe:

$$F_t = (L * e^{m*t}) * S_t$$

Se invece si avesse un **trend logistico** si utilizzerebbe questa formula:

$$F_t = \left(\frac{K*L*e^{m*t}}{k+L*(e^{m*t}-1)} \right) * S_t$$

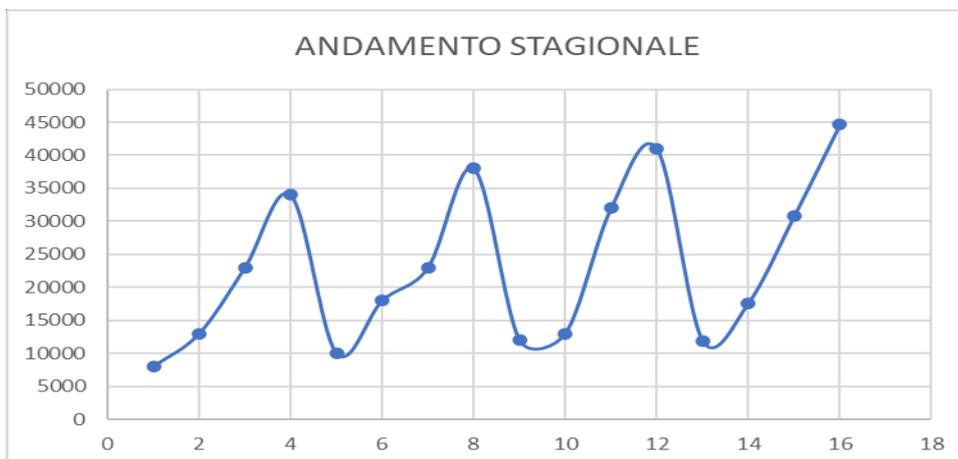


FIGURA 11: PREVISIONI PER I PERIODI 13,14,15 E 16 USANDO I DATI DELLA FIGURA 10 (TREND DI TIPO RETTA)

CONCLUSIONI

I metodi di tipo **statico** risultano sicuramente essere più facili da applicare rispetto ai metodi **dinamici** (capitolo 1.5) poiché non necessitano di un aggiornamento continuo delle previsioni effettuate. Ovviamente questa semplicità viene compensata da un rischio di errore previsionale più elevato.

1.5 - TECNICHE QUANTITATIVE DI PREVISIONE DELLA DOMANDA: I METODI

ADATTIVI

Come già accennato in precedenza, i metodi di tipo **adattivo** si contraddistinguono dal fatto che le previsioni di domanda vengono continuamente aggiornate per tenere conto dei dati reali di domanda. In sostanza, non appena trascorrerà almeno un periodo tra quelli che compongono l'**orizzonte di previsione** (ad esempio si ha un orizzonte di previsione di 3 periodi e non appena sarà trascorso il primo periodo si avrà a disposizione la domanda reale di quest'ultimo) si avranno a disposizione alcuni dei dati reali di domanda e si potranno confrontare gli stessi con le previsioni effettuate in modo da calcolare l'**errore di previsione** che è definito in questo modo:

$$E_t = F_t - D_t$$

E_t è l'errore di previsione per il periodo t , F_t è la previsione per il periodo t mentre D_t è la domanda reale nel periodo t . Ovviamente, se l'errore dovesse essere negativo la domanda sarebbe stata **sottostimata** mentre nel caso dovesse essere positivo la domanda sarebbe stata **sovrastimata**. Una volta calcolato l'errore di previsione si potrebbero (sempre nell'ambito di modelli di tipo adattativo) prendere le previsioni fatte utilizzando le equazioni riportate nel capitolo dei modelli statici (ad esempio $F_t = (L + m * t) * S_t$) dove la componente di livello e il coefficiente angolare m dipenderanno però dal tempo e aggiornarle tenendo conto dell'errore. Si vede dunque se l'errore previsionale è stato molto grande e nel caso si aggiornano i parametri del modello (tenendo conto dei nuovi dati di domanda a disposizione si ricalcola il trend destagionalizzando la domanda e si ricalcolano tutti i fattori stagionali). Si avrà dunque che la previsione di domanda (nel caso di trend lineare) per il periodo $t+i$ **effettuata nel periodo t** (e che poi verrà aggiornata in periodo successivo) sarà la seguente: $F_{t+i} = (L_t + m_t * (i)) * S_{t+i}$. Ovviamente, i parametri iniziali della previsione vengono calcolati utilizzando i metodi statici (si calcola la componente di livello iniziale, il coefficiente angolare iniziale e i fattori stagionali iniziali ragionando come si stesse utilizzando un metodo statico).

Metodo adattativo e trend logaritmico: $F_{t+i} = (L_t + m_t * \ln(i)) * S_{t+i}$

Metodo adattativo e trend esponenziale: $F_{t+i} = (L_t * e^{m_t * (i)}) * S_{t+i}$

Metodo adattativo e trend logistico: $F_{t+i} = \left(\frac{K_t * L_t * e^{m*(i)}}{k_t + L_t * (e^{m*(i)} - 1)} \right) * S_{t+i}$

I metodi di tipo adattativo si sposano perfettamente con la logica dell'**orizzonte mobile** (vedere capitolo 1.1).

In alternativa a ciò che è stato riportato precedentemente si possono utilizzare altre tecniche di tipo adattativo come:

- **la media mobile;**
- **la media mobile ponderata;**
- **lo smorzamento esponenziale semplice;**
- **il modello di Holt (smorzamento esponenziale con correzione per la tendenza);**
- **il modello di Winters (smorzamento esponenziale con correzione per la tendenza e per la stagionalità).**

MEDIA MOBILE

La media mobile è molto utile quando la domanda non manifesta tendenza o stagionalità osservabili e l'unica componente di rilievo è quella di **livello**.

La media mobile può essere descritta come una media "che si sposta": si definisce un orizzonte temporale su cui effettuare la media mobile (N) e ogni volta la si aggiorna togliendo i dati più vecchi di domanda e aggiungendo quelli nuovi in modo che il numero di dati resti sempre N (vedere figura 12 per un esempio). La previsione della domanda viene generalizzata a tutti i periodi futuri e la si aggiorna osservando i dati reali di domanda.

Matematicamente si ha:

$$L_t = F_{t+1} = \frac{D_t + D_{t-1} + \dots + D_{t-N+1}}{N}$$

$L_t = F_{t+1}$ poiché la stima della componente di livello t-esima coincide con la previsione della

domanda per il periodo t+1 (domanda dei vari periodi posta pari alla componente di livello). **N** è l'orizzonte temporale mentre D_t è la domanda **effettiva** avuta nel periodo t.

Una volta avuti i dati reali di domanda per il periodo t+1 si effettua la previsione per i j-esimi periodi successivi in questo modo:

$$L_{t+1} = F_{t+2} = \frac{D_{t+1} + D_t + \dots + D_{t-N+2}}{N}$$

Generalizzando al periodo t+i:

$$L_{t+i} = F_{t+j} = \frac{D_{t+i-1} + D_{t+i-2} + \dots + D_{t-N+i}}{N}$$

Si ha dunque che effettuando l'aggiornamento previsionale **in un periodo t+i**:

$L_{t+i} = F_{t+j} \quad \forall j > i$ fino ad ulteriore aggiornamento della previsione.

	PERIODI				
	1	2	3	4	5
DOMANDA	20	30	10		
PREVISIONE (F)				20	20
ALLA FINE DEL PERIODO 4 SI HA LA DOMANDA REALE DEL PERIODO 4					
	PERIODI				
	1	2	3	4	5
DOMANDA	20	30	10	30	
PREVISIONE (F)					23,33333
ALLA FINE DEL PERIODO 5 SI HA LA DOMANDA REALE DEL PERIODO 5					
	PERIODI				
	1	2	3	4	5
DOMANDA	20	30	10	30	20
PREVISIONE (F)					

Figura 12: ESEMPIO MEDIA MOBILE

$$F_4 = \frac{20+30+10}{3}$$

$$F_5 = \frac{30+10+30}{3}$$

MEDIA MOBILE PONDERATA

Un'alternativa alla media mobile è la **media mobile ponderata**, ovvero una media mobile in cui al posto di utilizzare una media di tipo algebrico si utilizza una media **pesata**. Essa vuole rimediare al problema della media mobile di non riuscire a seguire brusche variazioni della domanda. La media mobile ponderata sfrutta infatti un sistema di pesi che fa in modo che i valori meno recenti di domanda assumano meno importanza rispetto a quelli più recenti.

Come nel caso della media mobile semplice, anche la media mobile ponderata si usa per prevedere la domanda nel caso in cui non vi fossero stagionalità o tendenze osservabili.

Il procedimento da utilizzare in questo metodo di previsione è analogo a quello della media mobile semplice: si effettua la previsione su N periodi e si aggiorna di volta in volta la media cancellando i dati di domanda meno recenti e sostituendoli con quelli più recenti. Il principale problema della media mobile ponderata è quello della scelta dei pesi (**che vanno scelti in modo che la loro somma faccia uno**). La previsione della domanda si estende a tutti i periodi futuri e la si cambia quando la media mobile subirà un aggiornamento.

Matematicamente la media mobile ponderata si definisce in questo modo:

F_{t+j} è la previsione per il periodo t+j, L_{t+i} è la componente di livello del periodo t+i e D_{t+i-1} è la domanda **effettiva** avuta nel periodo t+i-1.

$$L_{t+i} = F_{t+j} = a_1 * D_{t+i-1} + a_2 * D_{t+i-2} + \dots + a_N * D_{t-N+i}$$

$$\text{Dove: } \sum_{i=1}^N a_i = 1 \quad a_i \text{ è l'i-esimo peso}$$

Dunque, effettuando l'aggiornamento della previsione in un **periodo t+i**:

$$L_{t+i} = F_{t+j} \quad \forall j > i \text{ fino ad ulteriore aggiornamento della previsione.}$$

SMORZAMENTO ESPONENZIALE SEMPLICE

Come con la media mobile e ponderata, anche lo **smorzamento esponenziale semplice** viene utilizzato quando la domanda non manifesta tendenza e stagionalità evidenti ($L_t = F_{t+i}$). Inoltre, similmente alle 2 medie mobili anche la formula dello smorzamento esponenziale si aggiorna in modo iterativo tenendo conto dei nuovi dati di domanda e la previsione della domanda si estende a tutti i periodi futuri fino a quando non si avranno a disposizione nuovi dati storici di domanda.

Lo smorzamento esponenziale semplice matematicamente è definito dalla seguente successione (previsione fatta per il periodo $t+i+1$):

$$L_{t+i} = F_{t+j} = a * D_{t+i} + (1 - a) * L_{t+i-1}$$

F_{t+j} è la previsione per il periodo $t+j$, L_{t+i} è la componente di livello del periodo $t+j$ mentre

a è definito **coefficiente di smorzamento** (è un parametro **compreso tra 0 e 1**) e D_{t+i} è la domanda **effettiva** avuta nel periodo $t+i$.

Dunque, aggiornando la previsione in **un periodo $t+i$** :

$L_{t+i} = F_{t+j} \quad \forall j > i$ fino ad ulteriore aggiornamento della previsione.

Ponendo $i=1$ si ha:

$$L_{t+1} = a * D_{t+1} + (1 - a) * L_t$$

Sostituendo ricorsivamente L_t all'equazione precedente si ottiene:

$$L_{t+1} = \sum_{n=0}^{t-1} a * (1 - a)^n * D_{t+1-n} + (1 - a)^t * D_1$$

Importante: nella scelta di a si deve tenere conto che per a molto grandi si ha maggiore prontezza ma minore stabilità mentre per a molto piccoli si ha minore prontezza ma maggiore stabilità del modello (figure 13 e 14).

NB: la stima iniziale della componente di livello è assunta pari alla media dei dati storici:

	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10			LO	20
PREVISIONE (F)				19,99999	19,99999	a	0,001
LIVELLO	20	20,01	19,99999				
ALLA FINE DEL PERIODO 4 SI HA LA DOMANDA REALE DEL PERIODO 4							
	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10	30			
PREVISIONE (F)					20,00999		
LIVELLO	20	20,01	19,99999	20,00999			
ALLA FINE DEL PERIODO 5 SI HA LA DOMANDA REALE DEL PERIODO 5							
	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10	30	20		
PREVISIONE (F)							
LIVELLO	20	20,01	19,99999	20,00999	20,00998		

Figura 13: ESEMPIO LIVELLAMENTO CON COEFFICIENTE DI SMORZAMENTO PICCOLO

$$L_0 = \frac{20+10+30}{3}$$

	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10			LO	20
PREVISIONE (F)				19,6	19,6	a	0,2
LIVELLO	20	22	19,6				
ALLA FINE DEL PERIODO 4 SI HA LA DOMANDA REALE DEL PERIODO 4							
	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10	30			
PREVISIONE (F)					21,68		
LIVELLO	20	22	19,6	21,68			
ALLA FINE DEL PERIODO 5 SI HA LA DOMANDA REALE DEL PERIODO 5							
	PERIODI						
	1	2	3	4	5		
DOMANDA	20	30	10	30	20		
PREVISIONE (F)							
LIVELLO	20	22	19,6	21,68	21,344		

Figura 14: ESEMPIO LIVELLAMENTO CON COEFFICIENTE DI SMORZAMENTO GRANDE

I 2 tipi di medie mobili e lo smorzamento esponenziale sono molto adatti a effettuare previsioni di domanda in ambienti più o meno **stabili** e in cui la domanda è pressoché costante (es: prodotto in fase di maturità).

MODELLO DI HOLT

Il modello di Holt è adatto quando oltre alla componente di livello si manifesta anche una certa tendenza di tipo **lineare** (retta del tipo: $Y(t) = L + m \cdot t$). Le

equazioni del modello sono le seguenti:

$$L_{t+i} = a * D_{t+i} + (1 - a) * (L_{t+i-1} + m_{t+i-1})$$

$$m_{t+i} = b * (L_{t+i} - L_{t+i-1}) + (1 - b) * (m_{t+i-1})$$

m_{t+i} è la previsione della tendenza (coefficiente angolare) per il periodo t+i, L_{t+i} è la previsione della componente di livello per il periodo t+i, **a e b** sono due coefficienti di smorzamento a scelta discrezionale (**compresi tra 0 e 1**) mentre D_{t+i} è la domanda effettiva avuta nel periodo t+i.

Ponendo i=1 si ha:

$$L_{t+1} = a * D_{t+1} + (1 - a) * (L_t + m_t)$$

$$m_{t+1} = b * (L_{t+1} - L_t) + (1 - b) * (m_t)$$

Inizialmente si inizializzano la tendenza (m) e la componente di livello (L) del periodo zero con i parametri L e m di una regressione lineare semplice e poi si aggiorna di volta in volta la previsione considerando i dati di domanda reali. Ovviamente, i coefficienti della retta che verranno trovati di volta in volta vengono utilizzati per effettuare previsioni su tutto l'orizzonte (figure 15 e 16).

Aggiornando la previsione **in un periodo t+i** si ha: $F_{t+j} = (L_{t+i} + m_{t+i} * (j - i)) \quad \forall j > i$
fino ad ulteriore aggiornamento della previsione.

ESEMPIO: j=4, i=2, t=1

$$F_5 = (L_3 + m_3 * (2))$$

ESEMPIO APPLICATIVO

	PERIODI						
	1	2	3	4	5		
DOMANDA	25	40	60			L0	17,5
PREVISIONE (F)				44,20795	50,88115	m0	6,6667
LIVELLO	24,16753	30,84357	37,53475			a	0,001
TENDENZA	6,666867	6,6687	6,673197			b	0,2
ALLA FINE DEL PERIODO 4 SI HA LA DOMANDA REALE DEL PERIODO 4							
	PERIODI						
	1	2	3	4	5		
DOMANDA	25	40	60	40			
PREVISIONE (F)					50,8761		
LIVELLO	24,16753	30,84357	37,53475	44,20374			
TENDENZA	6,666867	6,6687	6,673197	6,672356			
ALLA FINE DEL PERIODO 5 SI HA LA DOMANDA REALE DEL PERIODO 5							
	PERIODI						
	1	2	3	4	5		
DOMANDA	25	40	60	40	70		
PREVISIONE (F)							
LIVELLO	24,16753	30,84357	37,53475	44,20374	50,89522		
TENDENZA	6,666867	6,6687	6,673197	6,672356	6,676181		

Figura 15: ESEMPIO MODELLO DI HOLT

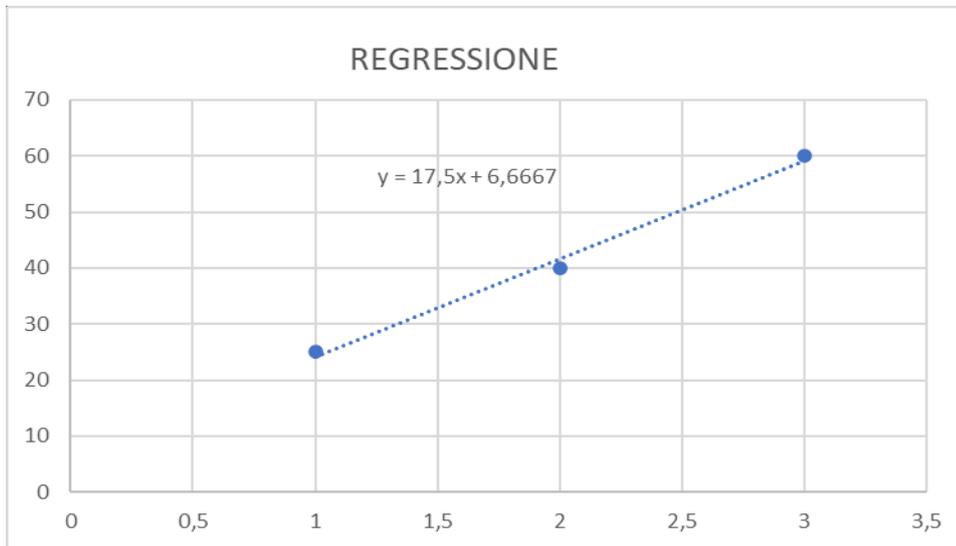


FIGURA 16: REGRESSIONE INIZIALE ESEMPIO HOLT

MODELLO DI WINTERS

Il modello di Winters (figura 17) è un'estensione del modello di Holt e incorpora una terza equazione che va a considerare anche fenomeni di **stagionalità** oltre che di **trend** (sempre di tipo lineare, cioè una retta del tipo: $Y(t) = L + m \cdot t$). Le equazioni del modello sono le seguenti:

$$L_{t+i} = a * \left(\frac{D_{t+i}}{S_{t+i}} \right) + (1 - a) * (L_{t+i-1} + m_{t+i-1})$$

$$m_{t+i} = b * (L_{t+i} - L_{t+i-1}) + (1 - b) * (m_{t+i-1})$$

$$S_{t+p+i} = \gamma * \left(\frac{D_{t+i}}{L_{t+i}} \right) + (1 - \gamma) * (S_{t+i})$$

m_{t+i} è la previsione della tendenza (coefficiente angolare) per il periodo $t+i$, L_{t+i} è la previsione della componente di livello per il periodo $t+i$, S_{t+p+i} è la previsione per il fattore stagionale nel periodo $t+p+i$ (p è il numero di stagioni in un determinato periodo), a , b e γ sono tre coefficienti di smorzamento a scelta discrezionale (**compresi tra 0 e 1**) mentre D_{t+i} è la domanda effettiva avuta nel periodo $t+i$.

Ponendo $i=1$ si ha:

$$L_{t+1} = a * \left(\frac{D_{t+1}}{S_{t+1}} \right) + (1 - a) * (L_t + m_t)$$

$$m_{t+1} = b * (L_{t+1} - L_t) + (1 - b) * (m_t)$$

$$S_{t+p+1} = \gamma * \left(\frac{D_{t+1}}{L_{t+1}} \right) + (1 - \gamma) * (S_{t+1})$$

NB: le stime iniziali delle componenti di livello, di tendenza e dei fattori stagionali sono ricavati utilizzando un modello di tipo statico con trend di tipo lineare (capitolo 1.4). Ovviamente, una volta ottenuti i vari parametri si continua ad applicare il modello aggiornando i vari parametri non appena si sapranno i nuovi dati di domanda.

Infine, aggiornando la previsione in un periodo $t+i$: $F_{t+j} = (L_{t+i} + m_{t+i} * (j - i)) * S_{t+j}$

$\forall j > i$ fino ad ulteriore aggiornamento della previsione.

ESEMPIO: $j=4, i=2, t=1$

$$F_5 = (L_3 + m_3 * (2)) * S_5$$

ESEMPIO APPLICATIVO

INIZIO PERIODO 5								
MESE	1	2	3	4	5	6		
DOMANDA	20	40	10	30			a	0,1
DESTAG.		27,5	22,5				b	0,3
LIVELLO	33,02419	27,8879	22,49606	17,61426			y	0,2
TREND	-4,84274	-4,93081	-5,06912	-5,01292			L0	37,5
FATTORI DI PERIODO	0,615385	1,454545	0,444444	1,714286			m0	-5
STAGIONALITA'	0,529915	1,584416	0,545055	1,554395	0,524948	1,584149	P	2
PREVISIONE	17,22222	44,65113	12,51287	27,08835	6,61505	12,02118	S1	0,529915
							S2	1,584416
FINE PERIODO 5								
MESE	1	2	3	4	5	6		
DOMANDA	20	40	10	30	5			
DESTAG.		27,5	22,5					
LIVELLO	33,02419	27,8879	22,49606	17,61426	12,29367			
TREND	-4,84274	-4,93081	-5,06912	-5,01292	-5,10522			
FATTORI DI PERIODO	0,615385	1,454545	0,444444	1,714286				
STAGIONALITA'	0,529915	1,584416	0,545055	1,554395	0,524948	1,584149		
PREVISIONE	17,22222	44,65113	12,51287	27,08835	6,61505	11,38759		
FINE PERIODO 6								
MESE	1	2	3	4	5	6		
DOMANDA	20	40	10	30	5	20		
DESTAG.		27,5	22,5					
LIVELLO	33,02419	27,8879	22,49606	17,61426	12,29367	7,732116		
TREND	-4,84274	-4,93081	-5,06912	-5,01292	-5,10522	-4,94212		
FATTORI DI PERIODO	0,615385	1,454545	0,444444	1,714286				
STAGIONALITA'	0,529915	1,584416	0,545055	1,554395	0,524948	1,584149		
PREVISIONE	17,22222	44,65113	12,51287	27,08835	6,61505	11,38759		

Figura 17: ESEMPIO MODELLO DI WINTERS

OSSERVAZIONE: come già accennato nello smorzamento esponenziale, scegliere i coefficienti di smorzamento nei modelli di Holt e di Winters ha impatto sulla stabilità e la prontezza dei modelli. In ambienti più stabili si possono scegliere coefficienti molto piccoli ma, come nel caso dell'esempio precedente, in ambienti più incerti conviene utilizzare coefficienti più elevati.

1.6 - TECNICHE DI MACHINE LEARNING NELLE PREVISIONI DI DOMANDA: RETI NEURALI MULTISTRATO (MPL) NON RICORRENTI E RICORRENTI

Un'alternativa ai metodi statici e a quelli dinamici per effettuare le previsioni di domanda è rappresentata dalle tecniche che sfruttano l'**Intelligenza artificiale (IA)** e in particolare il **machine learning (o data mining)**.

CENNI SUL MACHINE LEARNING (DATA MINING)

Il machine learning ha come obiettivo quello di utilizzare l'IA per numerosi scopi (segmentazione o clustering, classificazione, associazione e individuazione di pattern in serie temporali). Un esempio di machine learning potrebbe essere l'addestramento di un'IA a classificare dei fiori mai visti prima sulla base di dati in ingresso sulle caratteristiche di vari fiori (dimensione petali, colore, ...) in modo da imparare a "riconoscerli".

In sostanza, il data mining può essere classificato in:

DATA MINING DESCRITTIVO: segmentazione (clustering) e associazione;

DATA MINING PREDITTIVO: analisi di serie temporali e classificazione.

Il **data mining descrittivo** ha come scopo quello di **descrivere** dei dati a disposizione in modo da inserirli in degli insiemi denominati cluster (segmentazione o clustering) o in modo da formulare delle regole che descrivano i dati (associazione) come ad esempio: "se un cliente compra dei pannolini comprerà anche birra".

Il clustering è molto usato nel marketing per suddividere il mercato in varie tipologie di clienti e inoltre l'associazione può essere considerata anche una tecnica predittiva.

Invece, il **data mining** predittivo ha come obiettivo quello di **predire** delle uscite sulla base di ingressi noti e uscite noti. Nel caso della classificazione si ha ad esempio come ingresso la dimensione dei

petali o il colore del fiore e come uscita il tipo di fiore. L'obiettivo è dunque quello di istruire l'IA a riconoscere il tipo di fiore dandogli in ingresso dati di vari fiori e comunicando all'IA il loro tipo (vedendo così se essa è stato in grado di riconoscerlo). In futuro si daranno dunque in ingresso tutti i dati di altri fiori senza però far sapere all'intelligenza artificiale il loro tipo (che dovrà riconoscere da sola). Nel caso delle **serie temporali** (come nel caso di **dati storici di domanda**) si può parlare invece di tecniche di regressione visto che possono essere considerate tecniche di machine learning (cap 1.4).

RETI NEURALI

Nel machine learning si utilizzano numerosi algoritmi allo scopo di realizzare il clustering, l'associazione, etc. Uno strumento però molto utilizzato e che si presta a ogni tipo di applicazione di data mining è quello delle **reti neurali**. Quest'ultime possono essere viste come una sorta di "emulazione" dei neuroni umani visto che rappresentano un tentativo di replicare la struttura neuronale del cervello umano in campo informatico.

Un **neurone** è infatti una cellula del cervello umano che prende in input un segnale elettrico che viene rielaborato e trasmesso ad altri neuroni grazie a collegamenti sinaptici. In modo molto simile si può dunque definire una rete neurale come un insieme di neuroni collegati tra loro. Questa rete prende in input uno o più **segnali** e genererà uno o più **output**.

La più semplice rete neurale è denominata **percettrone** (figura 18) e venne definito da **Rosenblatt** tra la fine degli anni '50 e l'inizio degli anni '60. Esso è costituito semplicemente da una serie di **n ingressi** che vengono dati in input (y è funzione di n variabili), da una serie di **n collegamenti** (ciascuno definito da un **peso**) tra gli ingressi e un **blocco sommatore**, da una soglia collegata al blocco sommatore (che sarà definitiva da una funzione (che può essere definita come di **attivazione**) e da un output.

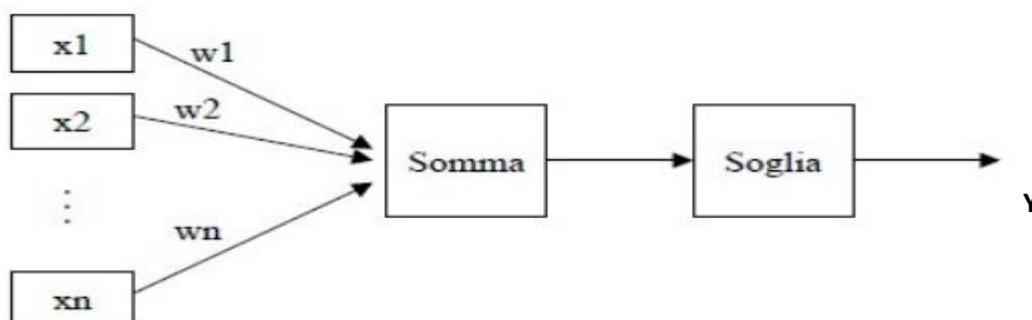


Figura 18: PERCETTONE

$$Y = \text{soglia}(\sum_{i=1}^n x_i * w_i)$$

x_i è l'i-esimo ingresso, w_i è l'i-esimo peso mentre Y è l'output. La soglia è la **funzione di attivazione** ed è in genere una tangente iperbolica, una retta o una sigmoide (una curva logistica (cap. 1.4) avente $K=0$, $L=1$ e $m=1$).

Ad esempio, nel caso della **tangente iperbolica** si ha:

$$Y(x_1, \dots, x_n) = \text{tanh}(\sum_{i=1}^n x_i * w_i)$$

In una rete neurale i dati con cui si lavora sono contenuti in un **data set** che si suddivide a sua volta in **training set**, **validation set** e **test set**. Il primo serve ad "addestrare" la rete grazie a un algoritmo; il secondo serve a fare in modo che non si verifichi **overfitting** (un adattamento eccessivo del modello ai dati del training set che rischia di peggiorare le performance della rete), facendo magari fermare l'algoritmo prima che l'errore sul validation set cresca troppo (early stopping), mentre il terzo serve per valutare le prestazioni della rete.

RETI NEURALI MULTISTRATO (MLP) E APPRENDIMENTO DELLA RETE

Una **rete neurale multistrato (figura 19) o perceptrone multistrato (multilayer perceptron)** è una rete neurale costituita da **più perceptroni (neuroni) collegati tra loro**: si danno in ingresso i dati del training set al primo strato (i vari strati sono denominati **hidden layers**) costituito da una serie di perceptroni in parallelo che genereranno poi delle uscite che saranno gli ingressi del secondo hidden layer (sempre costituito da perceptroni in parallelo). Le uscite del secondo hidden layer saranno gli ingressi del terzo hidden layer e così via fino ad arrivare all'output (o agli output nel caso di più uscite). Ogni j-esimo perceptrone è caratterizzato da una sua **funzione di attivazione** e da un serie di n pesi (n è il numero di perceptroni che inviano input al j-esimo perceptrone).

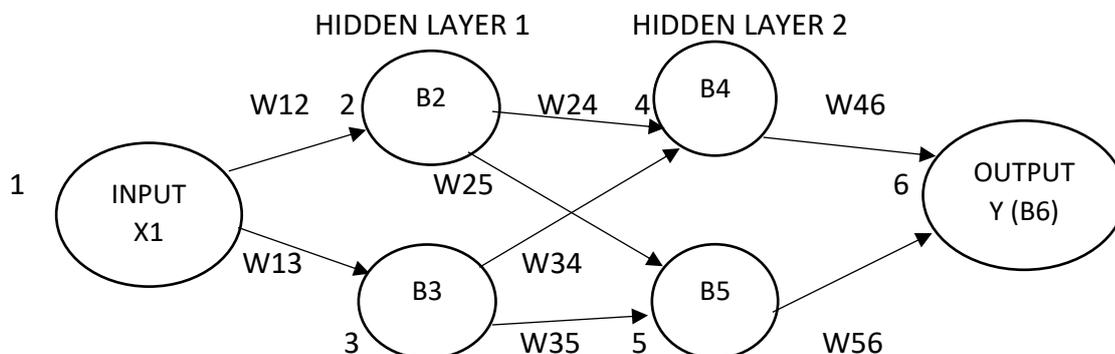


Figura 19: ESEMPIO MLP

W_{kj} è il peso associato all'arco che connette il nodo k con il nodo j mentre B_k è un parametro denominato **bias associato al nodo k** (permette uno "shift della funzione di attivazione e aiuta l'apprendimento della rete). Ogni nodo rappresenta un blocco sommatore e una soglia (dunque ad ogni nodo è associata una funzione di attivazione).

NB: con un bias l'uscita del perceptrone (figura 18) diventerebbe: $Y = \tanh(\sum_{i=1}^n x_i * w_i + bias)$

Supponendo di avere un solo ingresso (x_1), un'unica uscita del tipo $y=f(x)$ e che a ogni nodo dell'esempio compreso quello di output sia associata la funzione di attivazione Tanh, si ha che l'output Y è:

$$Y(x_1) = \tanh(w_{46} * (\tanh(\tanh(w_{12} * x_1 + B_2)) * w_{24} + \tanh(w_{13} * x_1 + B_3)) * w_{34} + B_4) + w_{56} * (\tanh(\tanh(w_{12} * x_1 + B_2)) * w_{25} + \tanh(w_{13} * x_1 + B_3)) * w_{35} + B_5) + B_6)$$

Una volta determinato l'output Y si possono dare alla rete altri ingressi in input trovando dunque un certo numero di uscite. Sia dunque **m** il numero di uscite totali dando un certo numero di input alla rete (**i dati del training set**); si ha che l'errore totale (E) è dato da:

$$E = \sum_{i=1}^n E_i \qquad E_i = F_i - Y_i$$

E_i è l'errore relativo all'i-esima volta in cui si ha un output dalla rete, F_i è la stima i-esima dell'uscita mentre y_i è l'uscita reale i-esima.

Mentre si ha che l'**errore quadratico medio o MSE** (cap.1.8) è:

$$MSE = \frac{\sum_{i=1}^m (E_i)^2}{m}$$

L'errore quadratico medio è molto utile **poiché permette l'apprendimento della rete e di aggiustare i parametri bias e pesi**. Infatti, inizialmente si applica un approccio denominato "forward" (applicazione degli ingressi) mentre infine si calcola l'MSE (che è una funzione che ha come variabili i pesi e i bias) e si cerca di **minimizzarlo** utilizzando metodi come la **discesa del gradiente** in modo da ottenere i nuovi pesi e i nuovi bias che minimizzino l'MSE (approccio definito "backward" visto che si confronta l'uscita reale con quella prevista). Ovviamente, prima di applicare la fase "forward" si assegna ad ogni arco e nodo un peso e un bias **casuale**. La combinazione dell'approccio backward e forward è detta **retropropagazione dell'errore (backpropagation)**.

NB: si cerca di evitare l'overfitting guardando l'MSE del validation set.

RETI NEURALI MULTISTRATO RICORRENTI E NON RICORRENTI

Una rete neurale multistrato si definisce ricorrente (figura 20) quando sono presenti dei “loop” (cicli) nei nodi. Questi loop prendono l’uscita del nodo e la ridanno in input allo stesso. Invece, una rete multistrato non ricorrente (feed-forward) è semplicemente una rete del tipo visto nell’esempio precedente. **Una rete ricorrente è molto utile nel caso in cui gli ingressi siano tempo varianti e le uscite siano influenzate dai valori passati degli ingressi.** Ovviamente questo tipo di rete sarà molto più complessa rispetto a una semplice rete non ricorrente.

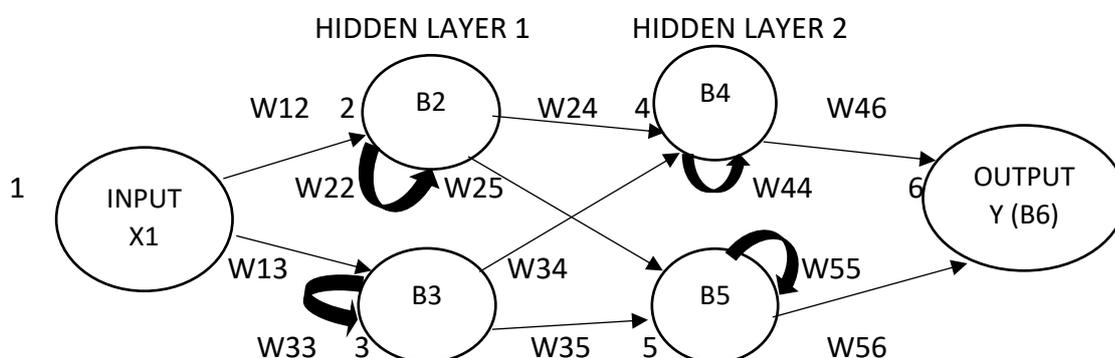


Figura 20: ESEMPIO RETE RICORRENTE CON LOOP SUL NODO 4 E SUL NODO 5

W_{kj} è il peso associato all’arco che connette il nodo k con il nodo j mentre B_k è un parametro denominato **bias associato al nodo k**.

In una rete ricorrente dunque si ha che applicando un nuovo ingresso (o un nuovo set di ingressi se la variabile Y dipende da più ingressi) si dovrà dare in input ai nodi con i loop la loro uscita durante l’applicazione dell’ingresso precedente. Per il resto, in una rete ricorrente si procede come in una rete feed – forward (calcolo dell’MSE e minimizzazione dello stesso con aggiornamento di bias e pesi).

Nella figura 20, supponendo di avere un solo ingresso (x_2), un’unica uscita del tipo $y=f(x)$ e che a ogni nodo dell’esempio compreso quello di output sia associata la funzione di attivazione Tanh, si ha che l’output Y è:

$$Y(x_2) = \tanh(w_{46} * (\tanh(\tanh(w_{12} * x_2 + B_2 + w_{22} * \tanh(w_{12} * x_1 + B_2))) * w_{24} + \tanh(w_{13} * x_2 - B_3 + w_{33} * \tanh(w_{13} * x_1 + B_3)) * w_{34} + w_{44} * (\tanh(\tanh(w_{12} * x_1 + B_2)) * w_{24} + \tanh(w_{13} * x_1 + B_3)) * w_{34} + B_4) + B_4) + w_{56} * (\tanh(\tanh(w_{12} * x_2 + B_2 + w_{22} * \tanh(w_{12} * x_1 + B_2))) * w_{24} + \tanh(w_{13} * x_2 - B_3 + w_{33} * \tanh(w_{13} * x_1 + B_3)) * w_{34} + w_{55} * (\tanh(\tanh(w_{12} * x_1 + B_2)) * w_{24} + \tanh(w_{13} * x_1 + B_3)) * w_{34} + B_5) + B_5) + B_6)$$

$$\tanh(w_{12} * x_1 + B_2)) * w_{25} + \tanh(w_{13} * x_2 + B_3 + w_{33} * \tanh(w_{13} * x_1 + B_3)) * w_{35} + w_{55} * (\tanh(\tanh(w_{12} * x_1 + B_2)) * w_{25} + \tanh(w_{13} * x_1 + B_3) * w_{35} + B_5) + B_6)$$

Ovviamente, applicando il primo ingresso (x_1) si ha che la rete neurale ricorrente si comporta come una semplice rete di tipo feed – forward. L'effetto dei loop si inizia infatti a vedere dall'applicazione dell'ingresso x_2 in poi.

CENNI AL METODO DELLA DISCESA DEL GRADIENTE

Come già accennato, per minimizzare l'MSE si possono utilizzare algoritmi simili al metodo della **discesa del gradiente** (figura 21).

DEFINIZIONE DI GRADIENTE

Si definisce gradiente di una funzione del tipo: $Y = f(x_1, \dots, x_n)$ (con $x_1, \dots, x_n \in R$) il **vettore delle derivate parziali di Y**:

$$\nabla Y = \frac{\delta Y}{\delta x_1} * \hat{i} + \dots + \frac{\delta Y}{\delta x_n} * \hat{j}$$

Il simbolo ∇ (nabla) indica il gradiente mentre \hat{i} e \hat{j} sono dei **versori** (vettori di modulo unitario).

FUNZIONAMENTO DEL METODO

Si vuole minimizzare una funzione del tipo: $Y = f(x_1, \dots, x_n)$ che magari è troppo complessa per essere minimizzata cercando i punti stazionari con i metodi tradizionali. Con il metodo della **discesa del gradiente** si prende come **direzione di discesa** il gradiente preso di segno negativo $-\nabla Y$ e si sceglie un **passo di discesa iniziale $\alpha(K=0)$** . Una volta trovati questi parametri si scelgono una serie di punti iniziali (**appartenenti al dominio di Y**) $X(K=0)=x_1(K=0), \dots, x_n(K=0)$ (nel caso delle reti neurali si hanno come punti iniziali i bias e i pesi della rete scelti casualmente) e si calcola il punto successivo:

$$X(K + 1) = X(K) + \alpha(K) * (-\nabla Y(X(K))).$$

Ad ogni iterazione si dunque aggiorna K ponendo $k = k+1$, si ricalcola il gradiente nei punti $X(K)$ e si sceglie un nuovo passo di discesa (oppure lo si può tenere fisso). L'algoritmo continua fino a quando non si avrà all'incirca il gradiente con componenti circa pari a zero (**il teorema di Fermat ci dice che quando il gradiente ha componenti nulle la funzione ha raggiunto un punto stazionario**).

Inoltre, si ha che il numero di volte in cui un algoritmo esplora tutti i dati d'ingresso aggiornando i pesi allo scopo di minimizzare l'MSE è detto **epoca**. In particolare, se i dati d'ingresso non vengono divisi in più "batch" si ha che un'epoca coincide con un'iterazione dell'algoritmo (ad esempio, se si dividessero i dati in 3 batch ci vorrebbero **3 iterazioni per completare un'epoca** poiché i pesi vengono aggiornati ogni volta che l'algoritmo osserva le uscite che i dati di un batch generano).

NB: nell'utilizzare Matlab non si sono divisi i dati d'ingresso in vari batch (1 epoca = 1 esplorazione di tutti i dati d'ingresso).

Un algoritmo di minimizzazione dell'MSE sceglie il numero di epoche ottimale guardando l'MSE del validation set (Matlab evita che l'algoritmo si adatti troppo al training set, ovvero il già citato **overfitting**, vedendo quando è minimizzato non tanto l'MSE del training set **ma quello del validation set**).

NB: nella discesa del gradiente la scelta del passo di discesa è fondamentale poiché influenza la velocità di convergenza dell'algoritmo!

		k	GRADIENTE X1	GRADIENTE X2	X1	X2	Y	
a	0,2	0	4	2	2	1	5	
		1	2,4	1,2	1,2	0,6	1,8	
		2	1,44	0,72	0,72	0,36	0,648	
		3	0,864	0,432	0,432	0,216	0,23328	
		4	0,5184	0,2592	0,2592	0,1296	0,083981	
		5	0,31104	0,15552	0,15552	0,07776	0,030233	
		6	0,186624	0,093312	0,093312	0,046656	0,010884	
		7	0,1119744	0,0559872	0,055987	0,027994	0,003918	
		8	0,06718464	0,03359232	0,033592	0,016796	0,001411	
		9	0,040310784	0,020155392	0,020155	0,010078	0,000508	
		10	0,02418647	0,012093235	0,012093	0,006047	0,000183	
			Y=(X1)^2+(X2)^2					
			GRADIENTE X1 =2*X1					
			GRADIENTE X2 =2*X2					
			X1(K+1)=X1(K)-a*GRADIENTE X1(K)					
			X2(K+1)=X2(K)-a*GRADIENTE X2(K)					

Figura 21: ESEMPIO DEL METODO DELLA DISCESA DEL GRADIENTE

Nell'esempio precedentemente riportato si è applicato il metodo della discesa del gradiente nella funzione: $Y(X1, X2) = X1^2 + X2^2$ ponendo il passo di discesa "a" uguale a 0,02 (costante) e scegliendo come punti iniziali $X1(0)=2$ e $X2(0)=1$. Dopo 10 iterazioni si ha che il punto di minimo è all'incirca: $Y=0$ con $X1=0$ e $X2=0$ (il gradiente $X1$, ovvero la derivata parziale della funzione Y rispetto a $X1$, e il gradiente $X2$, ovvero la derivata parziale di Y rispetto a $X2$, sono entrambi all'incirca nulli e di conseguenza il gradiente di Y ha entrambe le componenti pressoché nulle).

ESEMPI DI APPLICAZIONE DELLE RETI NEURALI ALLE PREVISIONI DI DOMANDA

1: RETE NEURALE "FEED – FORWARD"

Nel primo esempio si userà una rete neurale del tipo della figura 22 con 2 hidden layers da 15 neuroni ciascuno (implementata in Matlab):

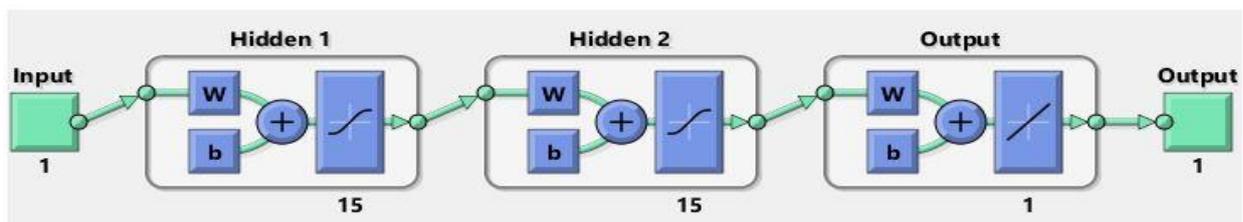


Figura 22: RETE NEURALE FEED – FORWARD PER ESEMPIO PREVISIONE DI DOMANDA

Dando in input i dati di domanda sotto riportati, ovvero gli stessi delle figure 10 e 11 e che hanno un andamento stagionale, alla rete neurale sopra riportata e utilizzando l'algoritmo del **GRADIENTE CONIUGATO SCALATO (scaled conjugate gradient)** e che è simile alla discesa del gradiente) per minimizzare l'MSE si ha:

PERIODO	1	2	3	4	5	6	7	8	9	10	11	12
DOMANDA	8000	13000	23000	34000	10000	18000	23000	38000	12000	13000	32000	41000

PERIODO	1	2	3	4	5	6	7	8	9	10	11	12
PREVISIONE	698,1411	10216,04	24984,12443	26149,3	12330,99	21985,43	22735,74	28053,83	10634,86	11528,71	32097,26	42119,74

Figure 23 e 24: DATI DI DOMANDA E PREVISIONI CON RETE NEURALE NON RICORRENTE

La tabella più in un alto riporta i dati del **data set** mentre le due tabelle più in alto sono frutto dell'elaborazione della rete neurale (essa riceve in input i **periodi**) e dà come output la domanda di quel periodo. Inoltre, il data set è stato diviso in questo modo: 70% training set, 25% validation set e 5% test set. Dunque, i primi 8 periodi sono utilizzati per l'addestramento, 3 per la validazione (il 9, il 10 e l'11) e uno per il testing (il 12). Infine, l'algoritmo utilizzato ha ritenuto opportune **4 epoche** poiché l'MSE del validation set risulta essere in questo modo minimizzato.



Figura 25: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO



Figura 26: ANDAMENTO EFFETTIVO DELLA DOMANDA NEI PRIMI 12 PERIODI

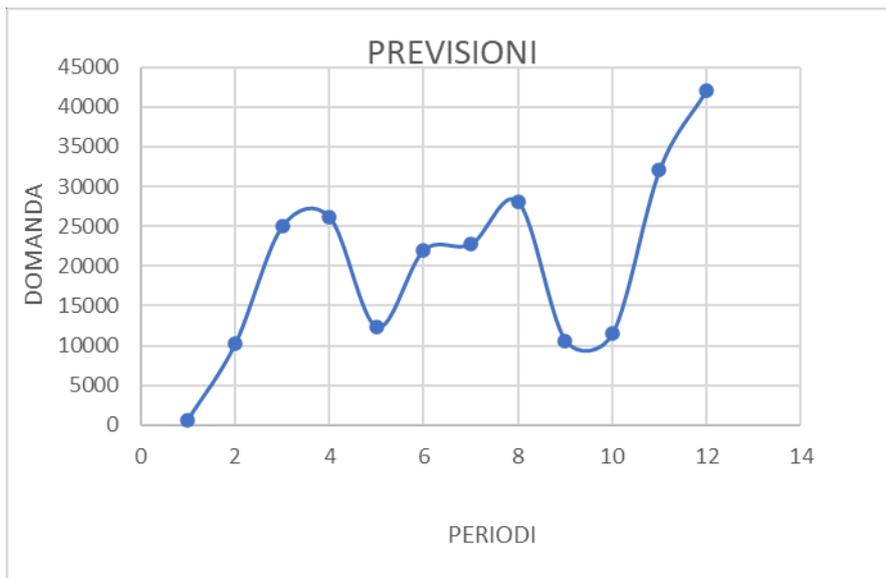


Figura 27: ANDAMENTO PREVISTO DELLA DOMANDA CON RETE NEURALE NON RICORRENTE

Confrontando i grafici delle figure 26 e 27 si nota come la rete neurale abbia fatto un ottimo lavoro e abbia capito più o meno l'andamento crescente misto a stagionale della curva di domanda. Questo risultato è stato possibile utilizzando una **funzione di attivazione del tipo tangente iperbolica** nei due hidden layers e una **funzione di attivazione di tipo retta presa** come nel nodo di output. L'MSE del test set ottenuto alla fine è di circa **1.253.828**.

2: RETE NEURALE "RICORRENTE"

Nel secondo esempio si userà una rete neurale del tipo della figura 28 con 2 hidden layers da 15 neuroni ciascuno (sempre implementata in Matlab):

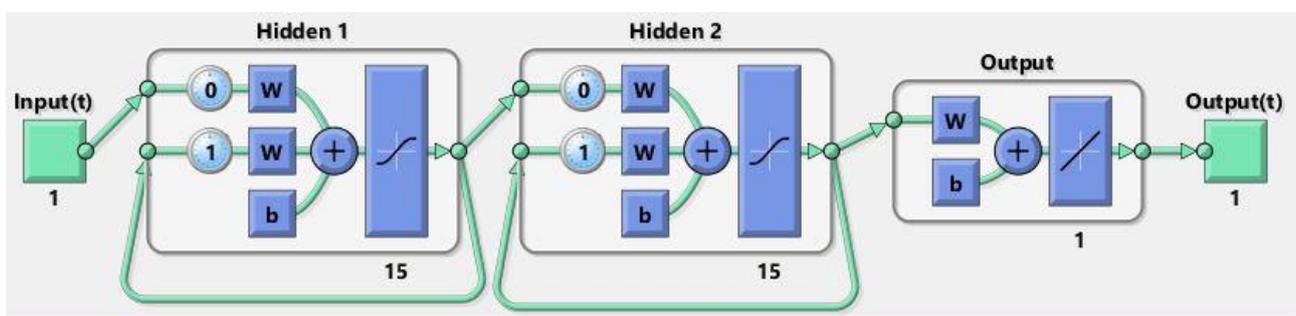


Figura 28: RETE NEURALE RICORRENTE PER ESEMPIO PREVISIONI DI DOMANDA

Nella rete è stato inserito un **time delay** che fa in modo che l'uscita di ogni loop venga data in input al nodo quando l'algoritmo di minimizzazione dell'MSE esplora l'ingresso successivo.

Dando in input gli stessi dati di domanda della rete neurale precedente (feed – forward), alla rete neurale sopra riportata e utilizzando anche questa volta l'algoritmo del **GRADIENTE CONIUGATO SCALATO** per minimizzare l'MSE si ha:

PERIODO	1	2	3	4	5	6	7	8	9	10	11	12
DOMANDA	8000	13000	23000	34000	10000	18000	23000	38000	12000	13000	32000	41000

PERIODO	1	2	3	4	5	6	7	8	9	10	11	12
PREVISIONE	12845,79	14681,82	16576,50524	18513,87	20472,53	22422,74	24326,13	26138	27811,5799	29303,482	30579,12	31616,88

Figure 29, 30: DATI DI DOMANDA E PREVISIONI CON RETE NEURAL RICORRENTE

La tabella più in un alto riporta i dati del **data set** mentre le due tabelle più in alto sono frutto dell'elaborazione della rete neurale (essa riceve in input i **periodi**) e dà come output la domanda di quel periodo. Inoltre, il data set è stato sempre diviso in questo modo: 70% training set (i primi 8), 25% validation set e 5% test set. Dunque, 8 periodi sono utilizzati per l'addestramento (i primi 8), 3 per la validazione e uno per il testing. Infine, l'algoritmo utilizzato ha ritenuto opportuno utilizzare **0 epoche** poiché l'MSE del validation set risulta essere in questo modo minimizzato.

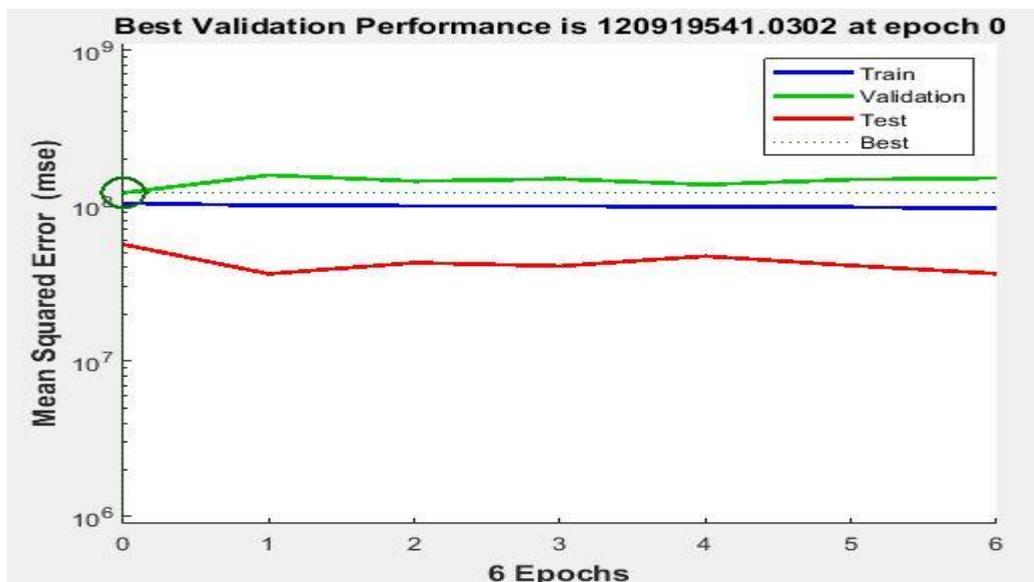


Figura 31: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO



Figura 32: ANDAMENTO EFFETTIVO DELLA DOMANDA NEI PRIMI 12 PERIODI

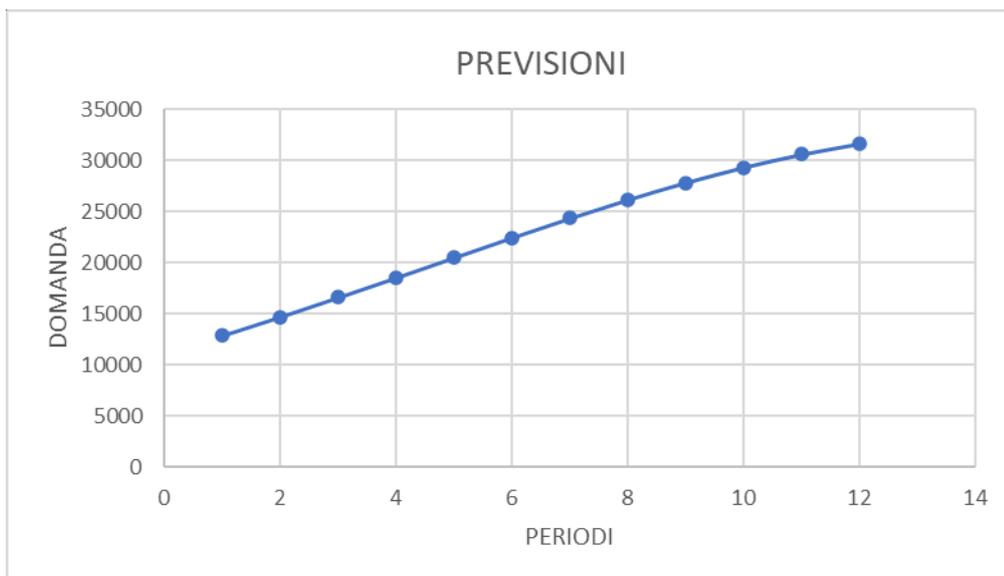


Figura 33: ANDAMENTO PREVISTO DELLA DOMANDA CON RETE NEURALE RICORRENTE

Confrontando i grafici delle figure 32 e 33 si nota come la rete neurale ricorrente (che utilizza la **tangente iperbolica** nei due hidden layers e una **funzione di attivazione di tipo lineare una retta, nel nodo di output**) non sia purtroppo riuscita a capire l'andamento stagionale della domanda **ma solo quello crescente**. Probabilmente, ciò è dovuto al fatto che i dati di domanda **non dipendono dai valori passati della stessa** e di conseguenza non sembra conveniente l'utilizzo di una rete ricorrente per effettuare previsioni di domanda in casi come questo (anche alla luce di un MSE molto

elevato sul test set: **88.042.861**). Nonostante ciò, il metodo verrà comunque utilizzato e confrontato con gli altri durante l'effettuazione delle previsioni di domanda per la Santoni (le domande sono stagionali e con una componente di trend) poiché nel caso riuscisse comunque a capire l'andamento crescente/ decrescente della domanda (componente di trend) potrebbe comunque generare buoni valori degli indicatori di performance (cap. 1.8) dato che le sottostime/sovrastime si compenserebbero a vicenda.

CONCLUSIONI

Le reti neurali sono sicuramente uno strumento molto potente per effettuare le previsioni di domanda e vari compiti relativi al data mining. Rispetto a metodi più tradizionali sono per molto più **complesse** perché necessitano di un'accurata progettazione in termini sia di layout che di scelta delle funzioni di attivazione. Bisogna inoltre prestare molta attenzione al problema dell'overfitting, al fatto che i pesi dei vari nodi influenzino la prestazione della rete (è consigliabile infatti provare pesi casuali diversi fino a che le prestazioni non siano ottimali) e a come viene diviso il data set (training set, validation set e test set).

1.7 - PREVISIONI DI DOMANDA IN AMBIENTE INCERTO E IL METODO MONTE

CARLO

Molte volte può capire che la domanda abbia una componente randomica talmente forte che si fatica ad usare sia tecniche di tipo statico che di tipo adattativo. In questi casi, potrebbe sicuramente essere conveniente l'utilizzo di metodi di previsione di tipo qualitativo (capitolo 1.3) ma nel caso si volessero utilizzare tecniche quantitative ciò è ancora possibile andando però più verso tecniche appartenenti alla statistica e che sfruttano le simulazioni e la statistica.

Come già accennato in precedenza, le situazioni in cui la domanda è molto incerta sono molteplici (concorrenti imprevedibili, mercato in continua evoluzione, ambiente politico instabile, etc.) e in questi casi, nel caso si avessero moltissimi dati storici di domanda, si potrebbe, sfruttando il teorema del limite centrale (che enuncia il fatto che **avendo un numero di dati molto grande si può approssimare la distribuzione di probabilità di questi dati con un curva di Gauss**).

CENNI DI STATISTICA

Si ipotizzi di avere una serie di dati a cui viene associata una certa probabilità. Questi dati seguiranno un andamento (distribuzione) che viene descritto da una **funzione di probabilità** che può essere sia continua che discreta.

Nel caso discreto avremo: $P(x \leq a) = \sum_{i=1}^a P(x_i)$

dove $P(x_i)$ è detta **funzione di massa di probabilità**, x_i è l'i-esimo dato mentre $P(x \leq a)$ rappresenta la probabilità che un dato x sia minore di un valore a .

Ovviamente, siccome: $\sum_{i=1}^{+\infty} P(x_i) = 1$ vale: $P(x > a) = 1 - P(x \leq a)$

Nel caso continuo avremo: $P(x \leq a) = \int_{-\infty}^a f(x) dx$

dove $f(x)$ è chiamata **funzione di densità di probabilità**.

Ovviamente anche qui avremo:

$$\int_{-\infty}^{+\infty} f(x) dx = 1 \text{ e } P(x > a) = 1 - P(x \leq a).$$

Nel caso continuo abbiamo inoltre una distribuzione molto particolare: **la gaussiana o curva di Gauss**.

La funzione densità di probabilità gaussiana è definita nel seguente modo:

$$f(x) = \frac{1}{\sqrt{2 * \pi * \sigma^2}} * e^{\frac{-(x-\mu)^2}{2*\sigma^2}}$$

dove σ^2 è detta **varianza** mentre μ è detto **valore atteso**. In particolare, la radice della varianza è detta **deviazione standard**. Il valore atteso della gaussiana può essere stimato tramite la **media aritmetica** mentre la **deviazione standard** utilizzando la **deviazione standard campionaria** (avendo un campione di dati di n elementi).

Dunque:

$$\mu \cong \bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad \text{e} \quad \sigma \cong S_n = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}$$

Inoltre, operando un'operazione definita standardizzazione si può praticamente "trasformare" una qualsiasi distribuzione gaussiana in una avente media nulla e varianza pari a 1 detta **normale standard** e che al posto di x utilizza una variabile detta z definibile in questo modo:

$$Z = \frac{X - \mu}{\sigma} \quad \text{e dunque:} \quad \mathbf{Z} = \frac{\mathbf{a} - \mu}{\sigma}$$

L'utilità della normale standard (figura 34) è che i suoi valori sono tabulati e possiamo conoscere $P(z \leq \mathbf{Z})$ usando delle semplici tabelle (figura 35).

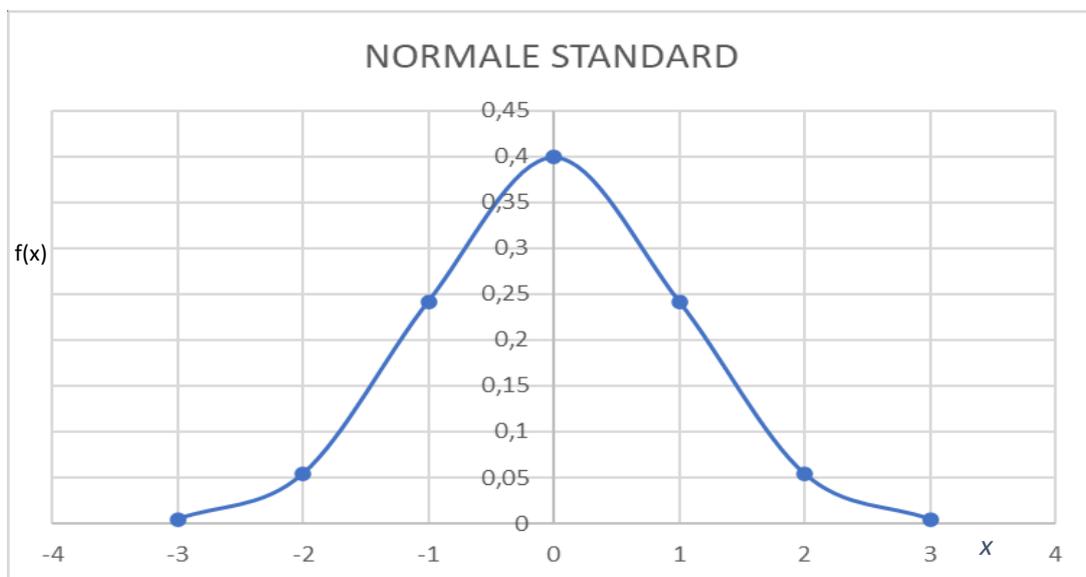


Figura 34: NORMALE STANDARD

z	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0.0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1.0	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2.0	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3.0	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998

Figura 35: TABELLA NORMALE

Dalla tabella sopra si sa ad esempio che: $P(z \leq 0,51) = 0,6950$

In conclusione, avendo una domanda con andamento aleatorio e con una certa distribuzione continua o discreta (anche ignota) ma avendo a disposizione un campione di dati di domanda molto grande, si può utilizzare il teorema del limite centrale e sfruttare la standardizzazione per vedere quant'è probabile che la domanda ricada in un certo range di valori.

I range possono essere calcolati in modo simile a come si fa per le classi di un istogramma (vedere metodo Monte Carlo).

IL METODO MONTE CARLO

Uno strumento molto potente nel caso in cui la domanda abbia una forte componente casuale è rappresentato dalle simulazioni come quella del **metodo Monte Carlo** (figura 36).

Il funzionamento di questo metodo è semplice:

1. si prendono i dati di domanda e li si ordinano in modo crescente;
2. si costruisce un **istogramma** con i dati appena ordinati;
3. si vedono le frequenze relative cumulative delle varie classi dell'istogramma;
4. si effettuano M simulazioni (più ne sono meglio è) generando M numeri casuali compresi tra zero e uno tramite la funzione CASUALE () di Excel;
5. si associa ogni numero casuale ad una frequenza relativa cumulativa di una classe;
6. si contano quanti numeri casuali sono associati ad una determinata classe;
7. si vede dunque qual è la probabilità che la domanda ricada in una determinata classe (range di valori).

Prima di illustrare un breve esempio di funzionamento del metodo è però opportuno definire bene come si costruisce un istogramma.

Quest'ultimo è semplicemente un grafico a barre in cui in ascissa vengono rappresentate le varie classi mentre in ordinata la frequenza delle varie classi. Quest'ultime rappresentano semplicemente i raggruppamenti dei dati che si hanno a disposizione (es: avendo dei dati che vanno da uno a trenta si potrebbero avere le seguenti classi di ampiezza 10: 1-10, 11-20 e 21-30). La frequenza relativa di una classe è semplicemente il numero di volte in cui i dati in essa contenuti appaiono diviso il numero totale di dati a disposizione (la somma delle frequenze relative fa ovviamente 1).

Il numero di classi si calcola in questo modo: $N = \sqrt{n}$ dove n è il numero di dati mentre N il numero di classi.

L'ampiezza delle varie classi sarà invece: $\frac{X_{max} - X_{min}}{N}$ dove le x al numeratore rappresentano semplicemente il valore più piccolo e più grande dei dati a disposizione.

Ad ogni classe potrò associare poi una frequenza relativa e una **frequenza cumulativa relativa** (frequenza della classe + frequenze delle classi precedenti). In termini probabilistici si ha che la frequenza cumulativa rappresenta la probabilità che i dati siano minori uguali dei dati appartenenti a quella classe.

PERIODI	1	2	3	4	5	6	7	8	9
DOMANDA	43	189	18	41	157	166	58	117	30
n	9								
N	3								
AMPIEZZA	57								
DATI ORDINATI	18	30	41	43	58	117	157	166	189
CLASSI	CLASSE 1	CLASSE 2	CLASSE 3			SIMULAZIONE	RISULTATO SIMULAZIONE		
	(18-75)	(76-132)	(133-189)			1	0,91		
FREQUENZA RELATIVA	0,555556	0,111111	0,333333			2	0,29		
F. RELATIVA CUMULATIVA	0,555556	0,666667	1			3	0,25		
RISULTATI SIMULAZIONE	8	1	6			4	0,45		
PROBABILITA' CLASSE	0,533333	0,066667	0,4			5	0,8		
VALORE MEDIO CLASSE	38	117	170,6667			6	0,45		
						7	0,9		
PREVISIONE PER IL PERIODO 10	96,33333					8	0,98		
						9	0,3		
						10	0,76		
						11	0,96		
						12	0,42		
						13	0,18		
						14	0,61		
						15	0,51		

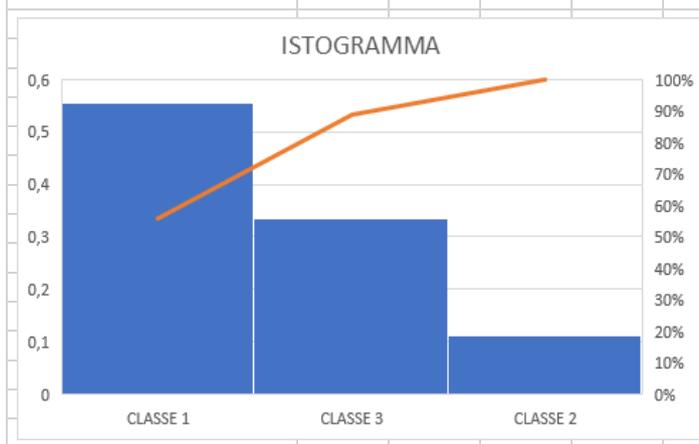


Figura 36: ESEMPIO METODO MONTECARLO

Nell'esempio, alla classe uno appartengono i valori di domanda 18, 30, 41, 43 e 58; alla classe due appartiene solo 117 mentre alla classe tre appartengono i valori 157, 166 e 189. Una volta determinate le classi si sono effettuate 15 simulazioni (per semplicità) e sono stati associati alla classe uno i valori minori di 0,55, alla classe due i valori compresi tra 0,56 e 0,67 mentre alla classe tre sono stati associati i valori compresi tra 0,68 e 1. In questo modo, si vede quante volte compare una determinata classe nella simulazione (risultati simulazione) e si può calcolare la probabilità che la domanda nel periodo 10 appartenga a una determinata classe (si ipotizza ovviamente che non possa essere un valore di domanda futuro maggiore di quelli già noti e ciò ha senso nel caso si abbiano molti dati storici) dividendo il numero di volte in cui compare in una

simulazione per il numero di simulazioni. Per effettuare la previsione si potrebbe poi calcolare il **valore medio di ogni classe** (si fa la media dei valori appartenenti a una classe) e moltiplicare i valori medi di ogni classe per la probabilità associata alla classe stessa. Si effettua poi la somma dei numeri ottenuti e si ha la **previsione di domanda per il prossimo periodo**.

In termini matematici si ha:

$$F_t = \sum_{i=1}^C P_i * \bar{X}_i$$

F_t è la previsione per il periodo t, C è il numero di classi, P_i è la probabilità associata all' i-esima classe mentre \bar{X}_i è il valore medio della classe i-esima.

Nb: nell'istogramma la curva in arancione rappresenta l'andamento della frequenza cumulativa (linea di Pareto).

1.8 - GLI ERRORI NEL PROCESSO DI PREVISIONE DI DOMANDA

Per concludere i metodi di previsione della domanda è opportuno accennare a quali siano le formule più utilizzate per valutare la bontà di un metodo di previsione di domanda una volta che si possono confrontare le previsioni con i dati reali di domanda.

A questo scopo si hanno:

- **l'errore di previsione;**
- **l'errore medio (mean error o ME);**
- **l'errore quadratico medio (main square errore o MSE);**
- **la deviazione assoluta media (mean absolute deviation o MAD);**
- **l'errore assoluto percentuale medio (mean absolute percentage error o MAPE);**
- **il bias;**
- **il tracking signal (TS);**
- **l'indicatore di Durbin – Watson (DW).**

ERRORE DI PREVISIONE

Come già accennato parlando delle previsioni adattative (cap 1.4), l'errore di previsione si definisce in questo modo:

$$E_t = F_t - D_t$$

E_t è l'errore di previsione per il periodo t , F_t è la previsione per il periodo t mentre D_t è la domanda reale nel periodo t . Ovviamente, se l'errore dovesse essere negativo la domanda sarebbe stata **sottostimata** mentre nel caso fosse positivo la domanda sarebbe stata **sovrastimata**

L'ERRORE MEDIO (ME)

Si definisce errore medio la media degli errori:

$$ME = \frac{\sum_{t=1}^N E_t}{N}$$

E_t è l'errore di previsione relativo al periodo t e N è il numero di previsioni effettuate.

L'ERRORE QUADRATICO MEDIO (MSE)

$$MSE = \frac{\sum_{t=1}^N (E_t)^2}{N}$$

E_t è l'errore di previsione relativo al periodo t e N è il numero di previsioni effettuate.

A differenza dell'ME, l'MSE sarà sicuramente positivo poiché gli errori vengono elevati al quadrato.

LA DEVIAZIONE ASSOLUTA MEDIA (MAD)

$$MAD = \frac{\sum_{t=1}^N |E_t|}{N}$$

$|E_t|$ è l'errore di previsione **assoluto** (si considera l'errore sempre positivo utilizzando il valore assoluto) relativo al periodo t ed **N** è il numero di previsioni effettuate.

Come L'MSE, **anche il MAD sarà sempre positivo.**

Inoltre, esiste una relazione tra il MAD e la **deviazione standard dell'errore** nel caso lo stesso fosse casuale e distribuito come una gaussiana (capitolo 1.6). Ovvero:

$$\sigma \cong 1,25 * MAD$$

L'ERRORE ASSOLUTO PERCENTUALE MEDIO (MAPE)

L'**errore assoluto percentuale medio** rappresenta semplicemente una media degli errori percentuali **assoluti** (valore assoluto di: errore/domanda):

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{E_t}{D_t} \right|}{N}$$

E_t è l'errore di previsione per il periodo t, **N** è il numero di previsioni effettuate mentre D_t è la domanda reale nel periodo t.

IL BIAS

Il **bias** è semplicemente la somma degli errori e dovrebbe fluttuare attorno allo zero per indicare che le previsioni effettuate siano state effettuate correttamente:

$$BIAS = \sum_{t=1}^N E_t$$

E_t è l'errore di previsione relativo al periodo t e **N** è il numero di previsioni effettuate.

IL TRACKING SIGNAL (TS)

$$TS = \frac{BIAS}{MAD}$$

Il **tracking signal** per dare un segnale che le previsioni effettuate siano state buone **dovrebbe attestarsi nell'intervallo ± 6 .**

INDICATORE DI DURBIN – WATSON (DW)

$$DW = \frac{\sum_{t=2}^N (E_t - E_{t-1})^2}{\sum_{t=1}^N (E_t)^2}$$

E_t è l'errore di previsione relativo al periodo t , E_{t-1} è l'errore di previsione relativo al periodo $t-1$ e N è il numero di previsioni effettuate.

L'indicatore di Durbin – Watson dovrebbe in genere attestarsi **tra 0 e 4** e inoltre:

- se $DW \cong 2$ gli errori sono sostanzialmente casuali e si compensano a vicenda;
- se $DW < 2$ gli errori sono autocorrelati positivamente (se in un periodo si commette un errore di un determinato segno nel periodo successivo si avrà un errore dello stesso segno);
- se $DW > 2$ gli errori sono autocorrelati negativamente (se in un periodo si commette un errore di un determinato segno nel periodo successivo si avrà quasi sicuramente un errore di segno diverso).

1.9 - CONCLUSIONI

Questo capitolo è servito ad introdurre i metodi di previsione (verranno ovviamente utilizzati solamente metodi quantitativi) che verranno testati nell'effettuare le previsioni di domanda relative all'azienda Santoni. Nell'effettuare le stesse di dovrà tenere conto di tutto ciò che è stato scritto nelle prime parti di questo primo capitolo (ambiente competitivo, orizzonte temporale, componenti della domanda, ...) in modo da capire se un metodo possa essere o meno utilizzato. Sarà poi molto importante valutare i vari metodi considerando gli errori di previsione per vedere quale metodo si dimostrerà il più adatto all'azienda. Per la valutazione si utilizzeranno ovviamente gli indicatori dell'errore riportati del capitolo 1.8 e si cercherà di utilizzare una parte dati aziendali per effettuare il **testing** dei vari metodi con i suddetti indicatori specialmente durante l'applicazione delle reti neurali (cap. 1.6, vedere il test set).

CAPITOLO 2

L'AZIENDA SANTONI S.P.A

2.1- PANORAMICA DELL'AZIENDA

STORIA AZIENDALE

La **Santoni S.p.a** (o **Santoni Shoes**) è un'azienda calzaturiera di Corridonia, un paese in provincia di Macerata (Marche). Essa nacque nel 1975 grazie all'intuizione di **Andrea Santoni**, che cercò di industrializzare una produzione di tipo artigianale cercando sempre di mantenere standard di qualità elevati. Il tipo di mercato a cui quest'azienda si rivolge è quello delle **calzature di lusso** sia femminili che maschili, in cui ha saputo imporsi come un importante attore a livello mondiale. Al giorno d'oggi la Santoni Shoes è guidata dal figlio di Andrea, Giuseppe Santoni, e dà lavoro a circa 650 persone.

CICLO DI VITA DELL'ORDINE

Il cliente emette un ordine che può essere sia per una scarpa "personalizzata" (su misura) che per una scarpa presente nel catalogo. Nel primo caso si parla di **Make to Measure** mentre nel secondo caso si parla di **Make to Order** (due termini associati ad una produzione di tipo PULL (cap. 1.1)). I clienti principali sono Businessman e professionisti, appassionati di moda e persone che acquistano una scarpa di lusso in occasione di cerimonie (es: matrimoni). Questi clienti possono essere sia italiani che stranieri (è cospicua la fetta di clienti proveniente dagli Stati Uniti). Una volta che l'ordine è stato emesso esso viene gestito dall'ufficio vendite che si interfaccia con la modelliera e la produzione per valutare la fattibilità dell'ordine nel caso esso sia della tipologia "Make to Order". Infatti, nel caso si tratti di un ordine Make to Measure si procede a inviare degli addetti presso il cliente per la misurazione del piede (procedura molto onerosa nel caso il cliente sia molto distante) e l'artigiano proporrà infine al cliente il modello di scarpe che lui stesso ritiene più adatto per il cliente. Una volta che un ordine può definitivamente partire l'ufficio tecnico genera tutta la documentazione necessaria a far partire la produzione. Le produzioni Make to Order (MTO) e Make to Stock (MTS) non avvengono in due linee separate ma vengono comunque gestiti

utilizzando fogli di carta di colore diverso per far capire agli operatori coinvolti se sia stia parlando di una calzatura personalizzata o meno.

Nel caso del MTS, parlando di calzature personalizzate, si ha una fase iniziale di progettazione: inizialmente viene realizzato un modello in legno sulla base delle misure fatte al cliente ed in seguito viene realizzato su carta anche un modello in 2D. Una volta realizzati questi due modelli si confrontano i requisiti dei clienti con le esigenze tecniche di produzione. Viene dunque avviata una fase di contrattazione tra il cliente e l'azienda in cui si cerca un compromesso tra queste due necessità. Una volta che questa fase è terminata si passa alla fase di prototipazione: si realizza un primo prototipo di scarpa che viene fatto provare al cliente (ovviamente i materiali utilizzati sono di minor valore rispetto a quelli del prodotto finito) e si procede alla realizzazione continua di prototipi fino a quando il cliente non riterrà lo stesso soddisfacente.

Una volta che il prototipo è stato accettato da cliente nel caso MTM (o che si ha una fattibilità produttiva nel caso MTO) la produzione può finalmente essere avviata. Quest'ultima è seguita personalmente da un artigiano.

IL PROCESSO PRODUTTIVO

Si analizzerà ora il processo produttivo dell'azienda prendendo come riferimento un prodotto "standard" (si parlerà dunque delle operazioni maggiormente effettuate).

Inizialmente vengono lavorate le pelli e le fodere (il rivestimento interno di una scarpa) tramite operazioni di taglio. Si poi effettua la spaccatura e la scarnitura delle tomaie (la parte esterna di una calzatura). In seguito, si procede all'orlatura delle tomaie tramite macchine da cucire e si poi applicano di puntali/forti alla tomaia orlata. Successivamente si preparano anche tacchi, soles e altri componenti del fondo che dovranno essere montanti. Una volta completate tutte queste fasi si dunque procede al montaggio delle varie calzature: lungo una manovia si montano le tomaie (grazie all'ausilio di forme di montaggio) e le soles. Inoltre, se la scarpa lo prevede, vengono anche montati i tacchi. Una volta che la produzione è terminata si procede all'imballaggio della scarpa: si puliscono le scarpe prima di inserirle nella loro confezione e si procede all'inscatolamento delle stesse e alla loro successiva spedizione. Durante la produzione si utilizzano dei cartellini e i dei disegni tecnici per comunicare le informazioni sui prodotti da realizzare.

I COMPONENTI UTILIZZATI NEL PROCESSO PRODUTTIVO

Prima di procedere con le previsioni di domanda è opportuno fare un piccolo excursus sui componenti che saranno oggetto delle previsioni di domanda e in particolare sui loro **codici identificativi**.

L'azienda Santoni utilizza dei **codici alfanumerici** per identificare i componenti: le prime due lettere identificano la **categoria merceologica** (tipologia di componente) mentre le lettere rimanenti identificano altre caratteristiche del componente (come il colore).

Le categorie merceologiche che verranno considerate per fare le previsioni sono:

- **FD** fondo (parte più bassa della scarpa e di cui fa parte la suola);
- **SP** sottopiede/taccola (componenti della scarpa che stanno rispettivamente a contatto con la parte inferiore del piede nel caso del sottopiede oppure che servono per i tacchi delle scarpe maschili nel caso della taccola);
- **TA** tacco alto;
- **TB** tacco basso;
- **IS** inserto/fussbet (componenti rispettivamente di scarpe e sandali che servono ad aumentarne la comodità).

CAPITOLO 3

I METODI DI PREVISIONE DI DOMANDA APPLICATI AL CASO SANTONI

3.1 – INTRODUZIONE

In questo capitolo verranno applicati alcuni dei metodi di previsione della domanda illustrati nel capitolo 1 alle categorie merceologiche utilizzate nelle calzature Santoni illustrate nel capitolo 2. Essendo la domanda di questi componenti di tipo **oscillatorio** (dovuti probabilmente in prevalenza a fenomeni di **stagionalità**) e avente anche un trend di tipo **lineare crescente**, i metodi utilizzati nell'effettuare le previsioni sono:

- il **metodo statico con destagionalizzazione a modello misto con trend di tipo lineare**;
- il **modello di Winters**;
- le **reti neurali multistrato ricorrenti e non ricorrenti**.

I dati utilizzati per effettuare le previsioni sono i **prelievi dei componenti** (per lavorazioni, per lavorazioni tramite terzi, ...) negli **anni 2017 e 2018**. Si sono poi utilizzati i prelievi nell'anno **2019** per valutare la bontà delle previsioni effettuate (test set, cap. 1.6) tramite gli indicatori riportati nel capitolo 1.8 (MAPE, MAD, TS, ...)

Le previsioni sono state effettuate **per mese** (si sono effettuate delle query sui dati storici in modo da estrapolare i prelievi delle varie categorie merceologiche in ogni mese). I mesi considerati sono dunque **36** (i primi 24 sono stati utilizzati per "addestrare" i vari metodi e per fare validation, che viene però solo eseguita con le reti neurali, mentre gli ultimi 12, ovvero quelli del 2019, sono stati utilizzati per effettuare il testing dei vari metodi).

Ogni mese è stato considerato pari a una **stagione** (numero di stagioni annuali pari a 12).

3.2– PREVISIONI DEI SOTTOPIEDI (SP)

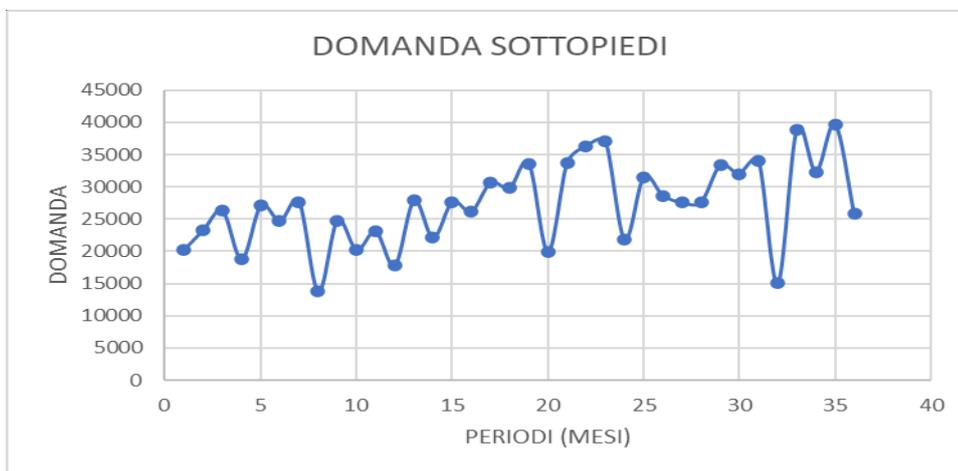


Figura 37: ANDAMENTO DELLA DOMANDA DI SOTTOPIEDI

METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO

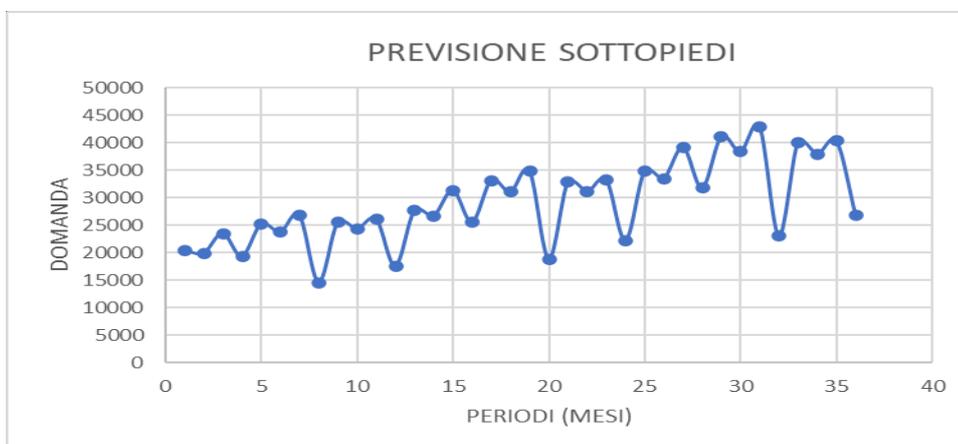


Figura 38: ANDAMENTO DELLA DOMANDA DI SOTTOPIEDI SECONDO IL METODO STATICO

ANNO 2019	
MSE	38484294
MAD	5271
BIAS	63246
TS	12
DW	0,47
MAPE	19%
ME	5271

Figura 39: INDICATORI SOTTOPIEDI METODO STATICO

MODELLO DI WINTERS

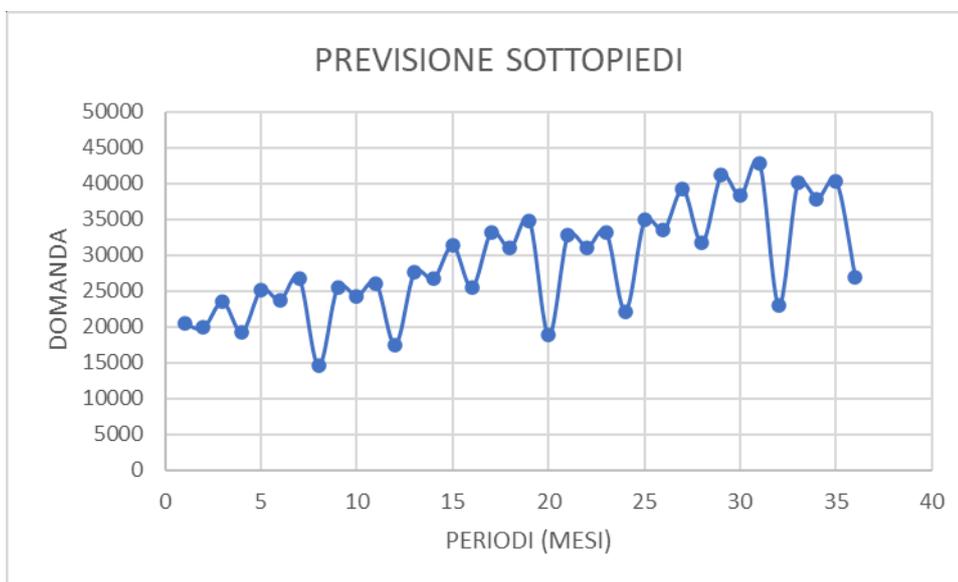


Figura 40: ANDAMENTO DELLA DOMANDA DI SOTTOPIEDI SECONDO IL MODELLO DI WINTERS

COEFFICIENTI DI SMORZAMENTO UTILIZZATI: $a = 0,0001$, $b=0,1$ e $\gamma=0,0001$.

ANNO 2019	
MSE	38482712
MAD	5270
BIAS	63243
TS	12
DW	0,47
MAPE	19%
ME	5270

Figura 41: INDICATORI SOTTOPIEDI MODELLO WINTERS

RETE NEURALE MULTISTRATO

Nell'effettuare le previsioni di domanda utilizzando le reti neurali multistrato si è utilizzata la rete neurale sotto riportata (figura 42) e costituita da **2 hidden layers da 30 nodi ciascuno** e implementata in Matlab (vedere appendice).

Questa rete è stata utilizzata sia per effettuare le previsioni di domanda dei sottopiedi sia per effettuare le previsioni delle altre categorie merceologiche. Le funzioni di attivazione che sono state utilizzate ogni volta che si è utilizzata la rete neurale (**scelte dopo aver fatto varie prove**) sono: **la TANGENTE IPERBOLICA negli hidden layers** mentre **una retta nel nodo di output**. Inoltre, ogni volta che si è utilizzata questa rete si è diviso il data set in questo modo: 40% (i primi 15 periodi) training, 26% validation (9 periodi) e 34% testing (gli ultimi dodici periodi, **ovvero l'anno 2019**).

NB: l'algoritmo utilizzato per minimizzare l'MSE è quello del GRADIENTE CONIUGATO SCALATO (cap. 1.6).

Nel caso dei sottopiedi il numero di epoche individuato dall'algoritmo di minimizzazione dell'MSE è **9** (fig. 43)

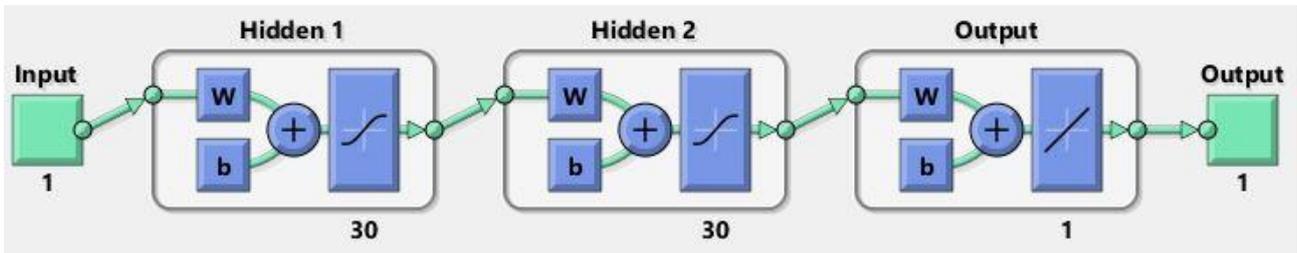


Figura 42: RETE NEURALE MULTISTRATO UTILIZZATA NELLE PREVISIONI DI DOMANDA

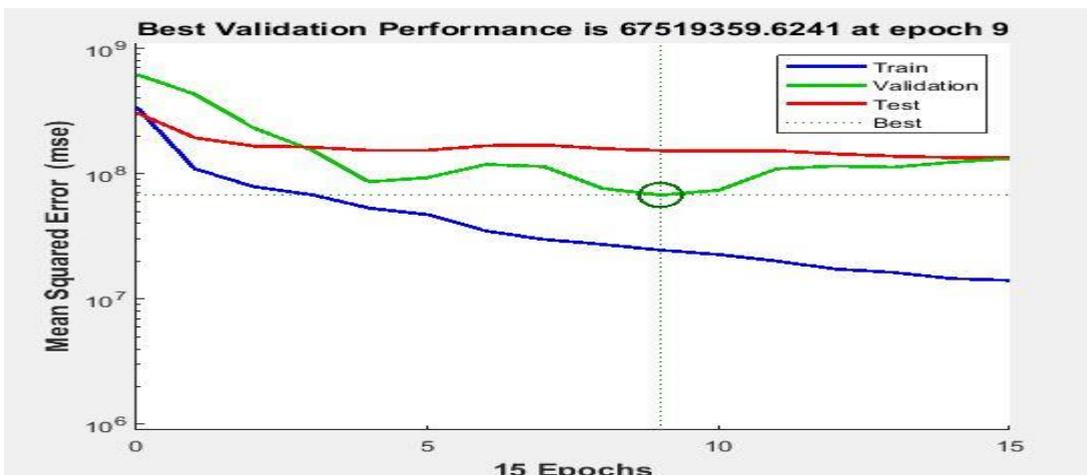


Figura 43: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (SOTTOPIEDI)

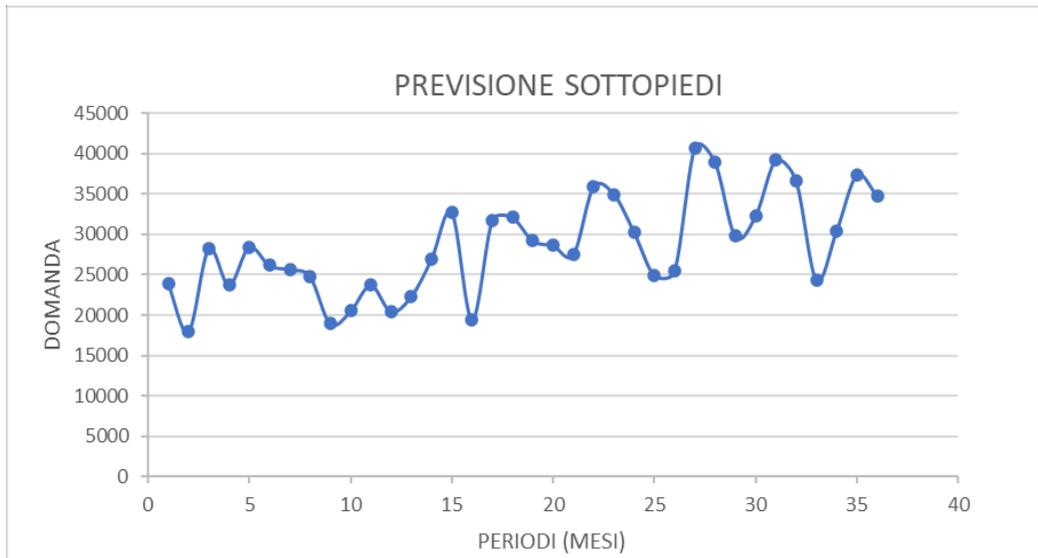


Figura 44: ANDAMENTO DELLA DOMANDA DI SOTTOPIEDI SECONDO LA RETE NEURALE MULTISTRATO

ANNO 2019	
MSE	96347000
MAD	7697
BIAS	28084
TS	4
DW	2,08
MAPE	31%
ME	2340

Figura 45: INDICATORI SOTTOPIEDI RETE NEURALE MULTISTRATO

RETE NEURALE MULTISTRATO RICORRENTE

Nell'effettuare le previsioni di domanda utilizzando le reti neurali multistrato **ricorrenti** si è utilizzata la rete neurale sotto riportata (figura 45) e costituita da **2 hidden layers da 30 nodi ciascuno** e avente un **time delay (ritardo)** sui nodi (vedere cap. 1.6). Questa rete è stata implementata in Matlab (vedere appendice) ed è servita sia per effettuare le previsioni di domanda dei sottopiedi sia per effettuare le previsioni delle altre categorie merceologiche. Le funzioni di attivazione che sono state utilizzate ogni volta che si è utilizzata la rete neurale ricorrente (**scelte dopo aver fatto varie prove**) sono: la **TANGENTE IPERBOLICA** negli **hidden layers** mentre **una retta nel nodo di output** (le stesse funzioni di attivazioni utilizzate anche nelle reti multistrato semplici).

Inoltre, ogni volta che si è utilizzata questa rete si è diviso il data set in questo modo: 40% (i primi 15 periodi) training, 26% validation (9 periodi) e 34% testing (gli ultimi dodici periodi, **ovvero l'anno 2019**).

NB: l'algoritmo utilizzato per minimizzare l'MSE è quello del GRADIENTE CONIUGATO SCALATO (cap. 1.6).

Nel caso dei sottopiedi il numero di epoche individuato dall'algoritmo di minimizzazione dell'MSE è **4** (fig. 47)

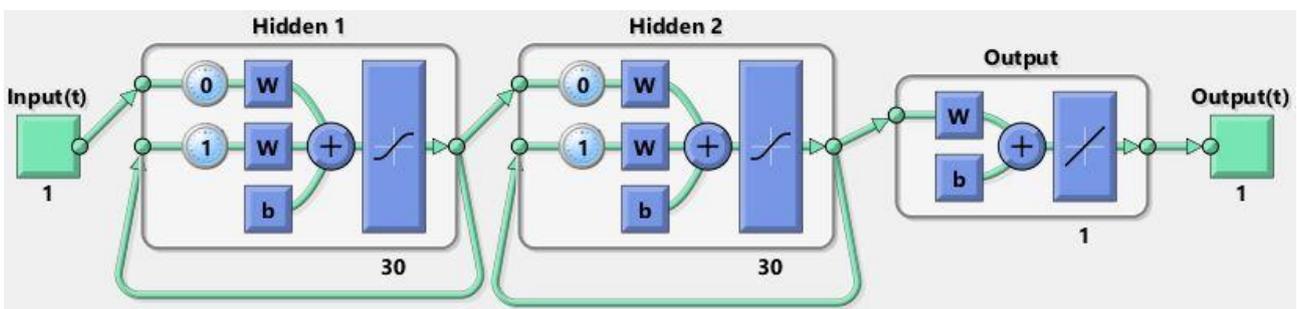


Figura 46: RETE NEURALE MULTISTRATO RICORRENTE UTILIZZATA NELLE PREVISIONI DI DOMANDA

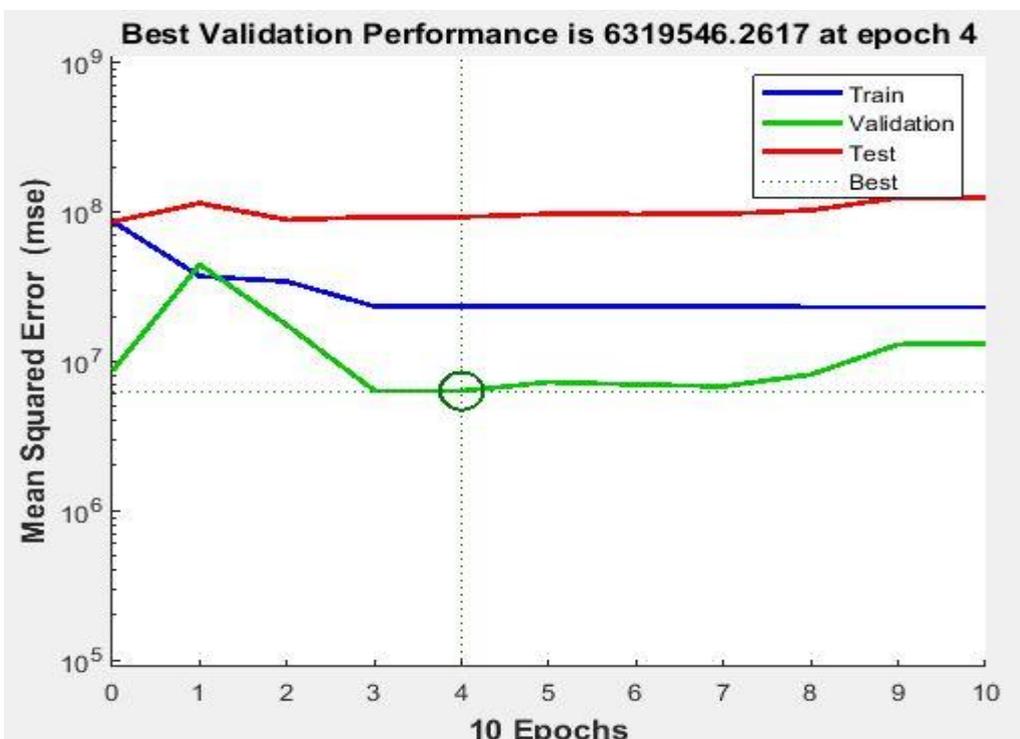


Figura 47: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (SOTTOPIEDI)

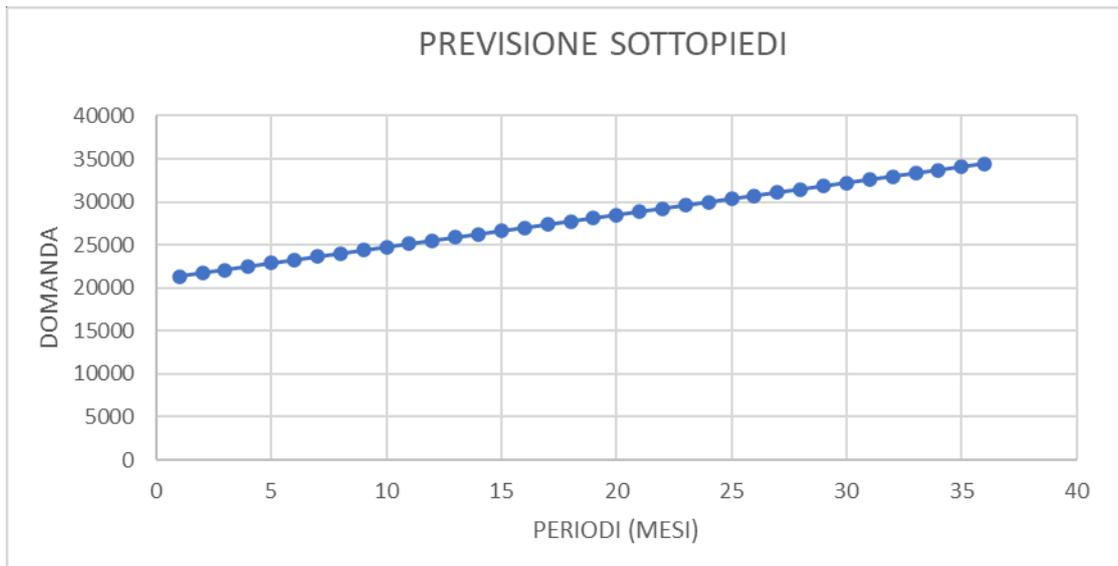


Figura 48: ANDAMENTO DELLA DOMANDA DI SOTTOPIEDI SECONDO LA RETE NEURALE MULTISTRATO RICORRENTE

ANNO 2019	
MSE	41521002
MAD	4408
BIAS	22305
TS	5
DW	2,6
MAPE	19%
ME	1859

Figura 49: INDICATORI SOTTOPIEDI RETE NEURALE MULTISTRATO RICORRENTE

CONCLUSIONI: QUAL È IL METODO DI PREVISIONE MIGLIORE NEL CASO DEI SOTTOPIEDI?

Osservando gli indicatori relativi a ogni metodo previsionale (figure 39, 41, 45 e 49) si può notare come il metodo peggiore sia la **rete neurale multistrato non ricorrente** avendo i valori peggiori sia in termini di MAPE (31%), di MSE e di MAD (è però interessante notare come il TS sia compreso nell'intervallo tra +6 e -6, cap. 1.8). Invece, per quanto riguarda il metodo migliore si ha che, guardando solamente gli indicatori, esso è rappresentato dalla **rete neurale multistrato ricorrente**. Infatti, **pur generando avendo un andamento di tipo lineare della domanda** essa riesce a generare un valore del MAPE uguale a quello del modello di Winters e del metodo statico (19%), valori migliori di ME e BIAS e un TS compreso tra +6 e -6. Infine, si ha che il modello di Winters e il metodo statico

hanno performato in maniera simile con il modello di Winters che ha però performato in maniera leggermente migliore (valori di ME, BIAS, MSE e BIAS leggermente più bassi).

Volendo “stilare” una classifica dei metodi nel caso dei sottopiedi si ha:

1. RETE NEURALE MULTISTRATO RICORRENTE;
2. MODELLO DI WINTERS;
3. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO;
4. RETE NEURALE MULTISTRATO NON RICORRENTE.

Infine, prima di concludere è bene accennare come nel metodo statico e nel modello di Winters si abbia un indicatore di Durbin – Watson (cap. 1.8) minore di 2 a **sottolineare una correlazione positiva negli errori** (si tendono ad accumulare errori di sovrastima della domanda). Nella rete neurale ricorrente si ha invece un indicatore di Durbin – Watson maggiore di 2 (**correlazione negativa degli errori** che sottolinea l'insieme di sovrastime e sottostime) mentre in quella non ricorrente si ha un indicatore di Durbin – Watson circa pari a 2 (gli errori si dispongono in maniera **casuale** senza un pattern preciso).

3.3– PREVISIONI DEI FONDI (FD)

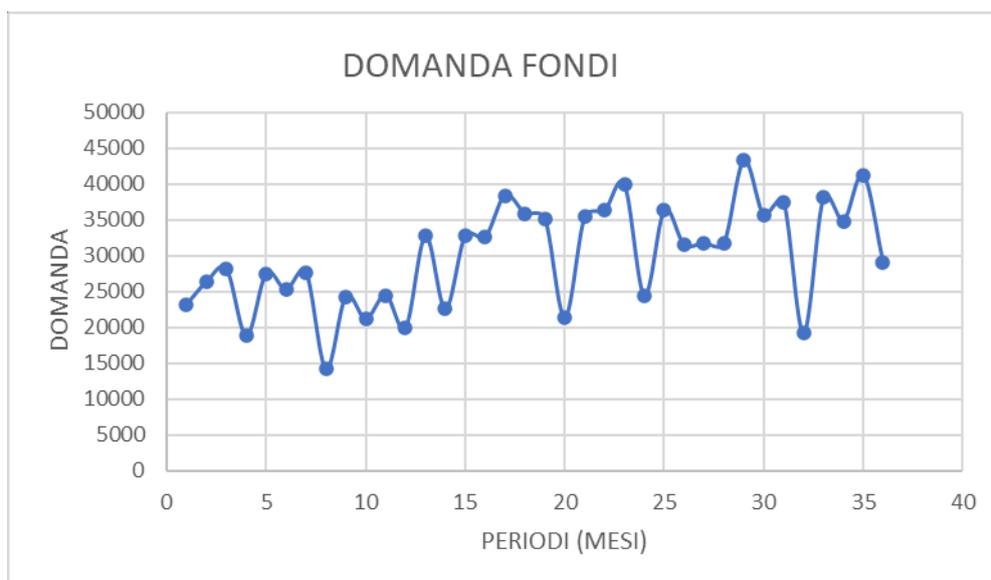


Figura 50: ANDAMENTO DELLA DOMANDA DI FONDI

METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO

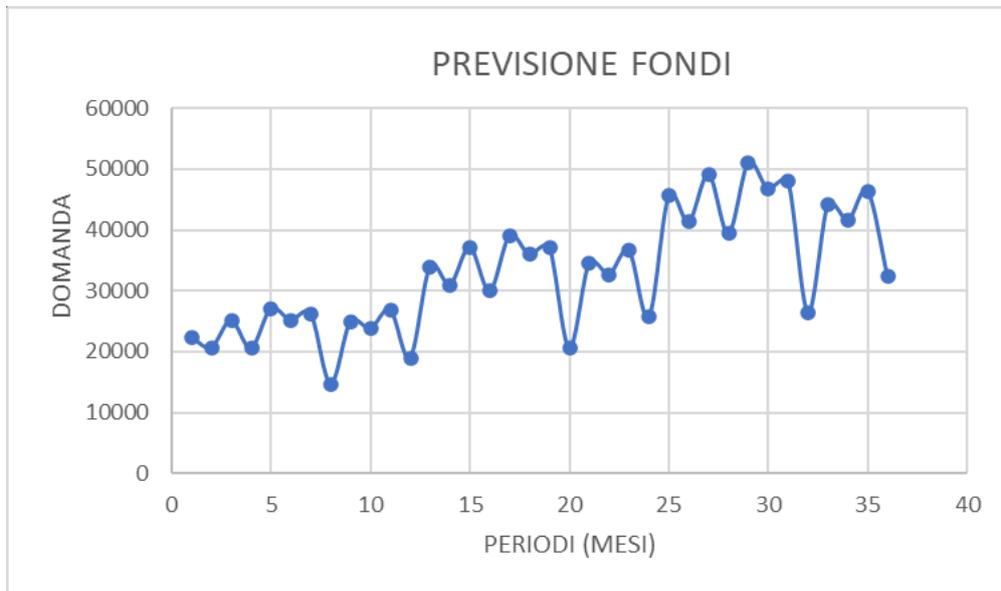


Figura 51: ANDAMENTO DELLA DOMANDA DI FONDI SECONDO IL METODO STATICO

ANNO 2019	
MSE	84077840
MAD	8498
BIAS	101977
TS	12
DW	0,18
MAPE	26%
ME	8498

Figura 52: INDICATORI FONDI METODO STATICO

MODELLO DI WINTERS

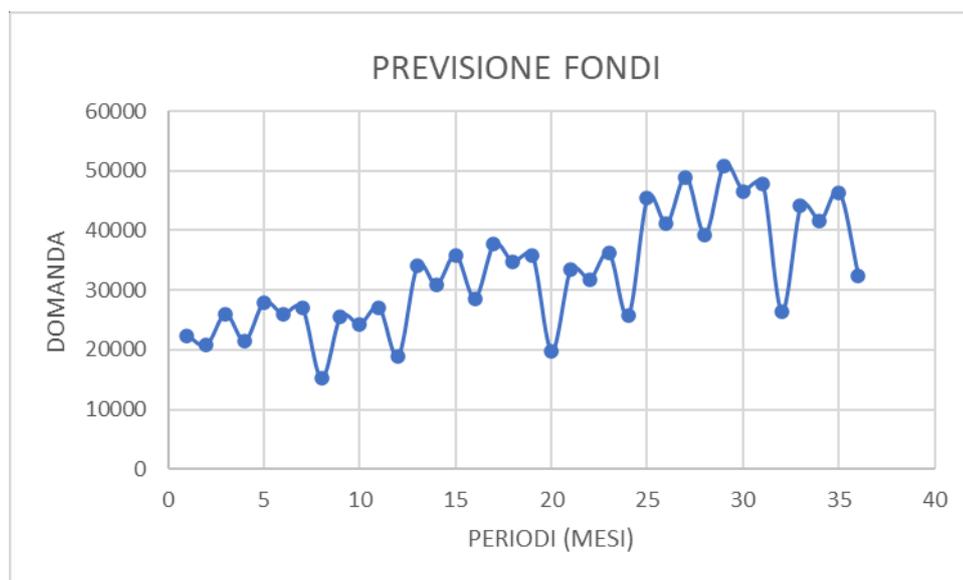


Figura 53: ANDAMENTO DELLA DOMANDA DI FONDI SECONDO IL MODELLO DI WINTERS

COEFFICIENTI DI SMORZAMENTO UTILIZZATI: $\alpha = 0,1$, $b=0,1$ e $\gamma=0,0001$.

ANNO 2019	
MSE	82195912
MAD	8411
BIAS	100938
TS	12
DW	0,18
MAPE	26%
ME	8411

Figura 54: INDICATORI FONDI MODELLO WINTERS

RETE NEURALE MULTISTRATO

Utilizzando sempre la rete neurale riportata in figura 42 e 12 epoche (fig. 55) i hanno i seguenti risultati:

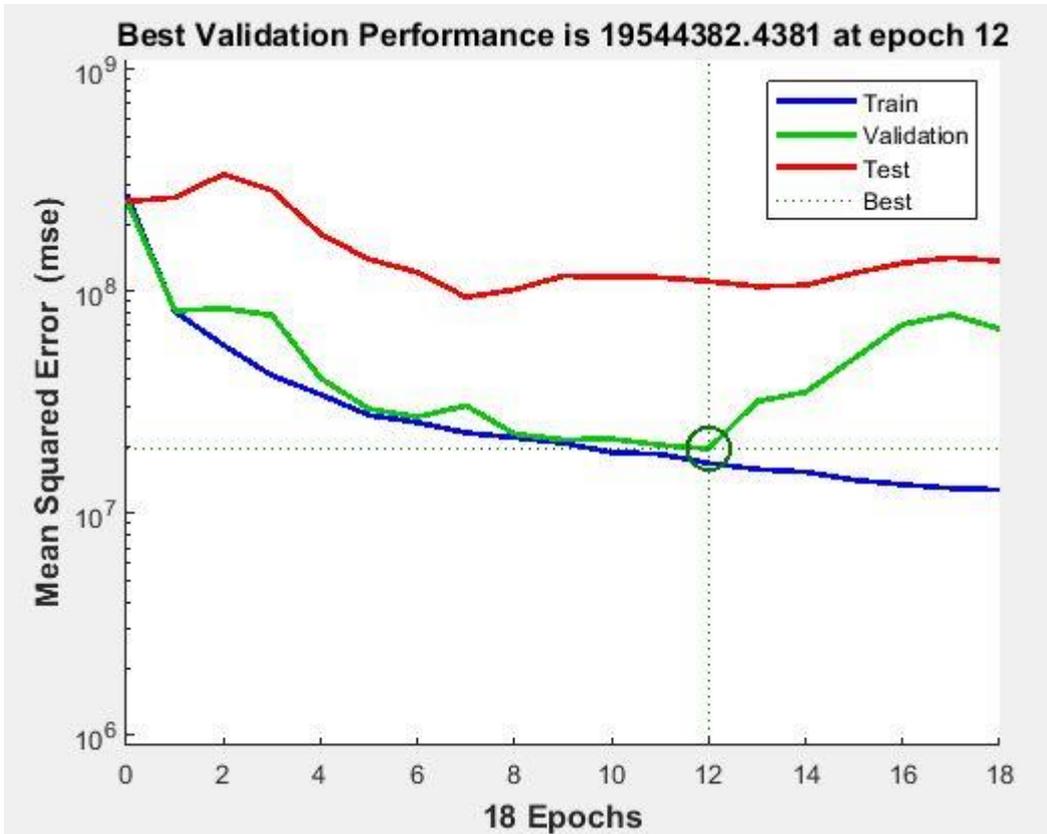


Figura 55: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (FONDI)

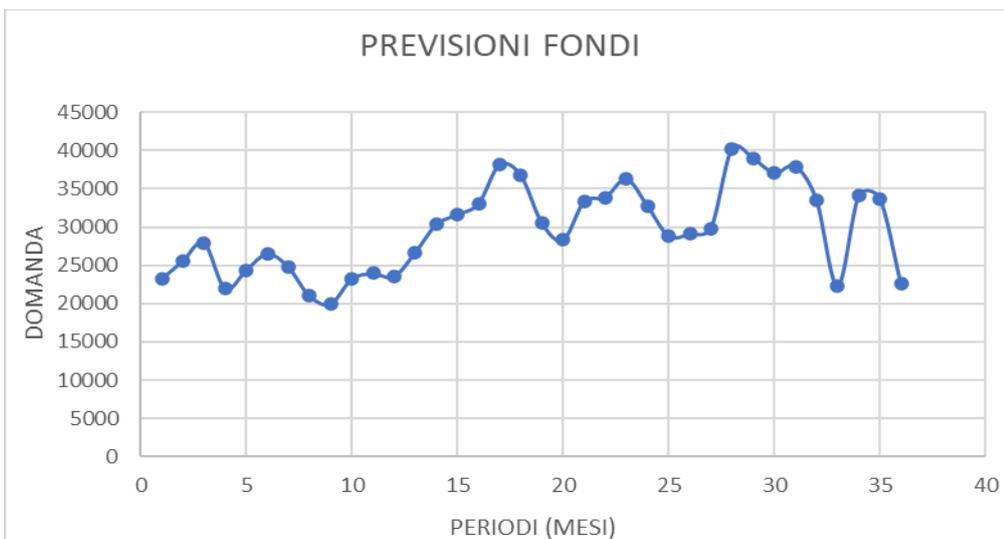


Figura 56: ANDAMENTO DELLA DOMANDA DI FONDI SECONDO LA RETE NEURALE MULTISTRATO

ANNO 2019	
MSE	59445544
MAD	5957
BIAS	-21721
TS	-4
DW	2,4
MAPE	20%
ME	-1810

Figura 57: INDICATORI FONDI RETE NEURALE MULTISTRATO

RETE NEURALE MULTISTRATO RICORRENTE

Utilizzando la rete neurale ricorrente riportata in figura 46 e 11 epoche (fig. 58) si ha la seguente situazione:

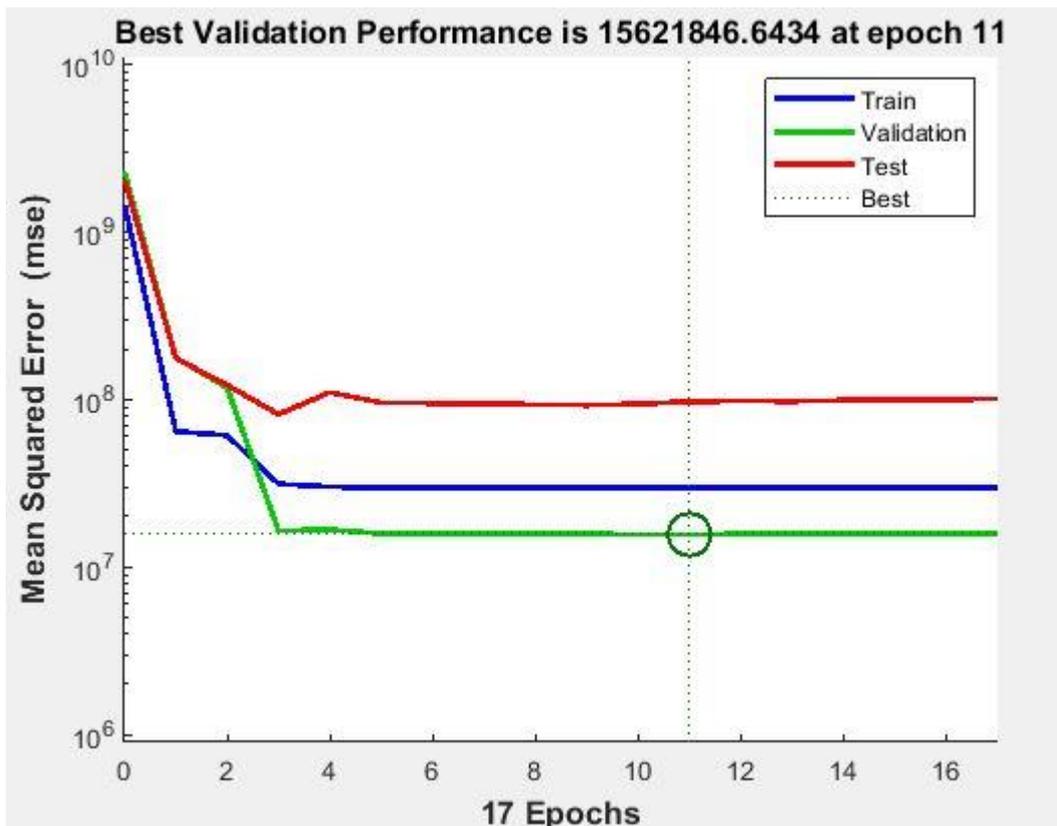


Figura 58: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (FONDI)

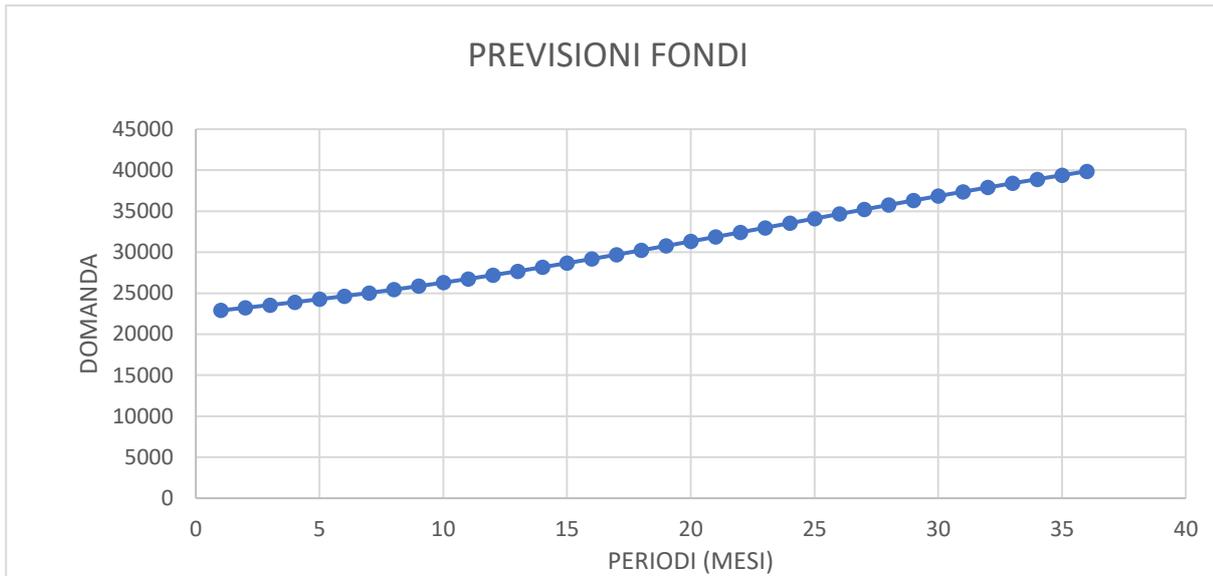


Figura 59: ANDAMENTO DELLA DOMANDA DI FONDI SECONDO LA RETE NEURALE MULTISTRATO RICORRENTE

ANNO 2019	
MSE	48266378
MAD	4741
BIAS	34698
TS	7
DW	1,93
MAPE	18%
ME	2892

Figura 60: INDICATORI FONDI RETE NEURALE MULTISTRATO RICORRENTE

CONCLUSIONI: QUAL È IL METODO DI PREVISIONE MIGLIORE NEL CASO DEI FONDI?

Osservando gli indicatori relativi a ogni metodo previsionale (figure 52, 54, 57 e 60) si può osservare come i metodi migliori siano la **rete neurale non ricorrente** e la **rete neurale ricorrente**. Infatti, sia il metodo statico che il modello di Winters hanno un MSE molto elevato, un MAPE del 26%, BIAS, ME e MAD molto elevati e un TS di 12 (è interessante notare come questi due metodi abbiano performato in maniera molto simile come nel caso dei sottopiedi con il modello di Winters che ha però performato leggermente meglio). Invece, le due reti neurali hanno un TS che è in modulo

inferiore a 12. Dovendo dunque scegliere il metodo migliore tra queste due reti ci si potrebbe orientare verso la **rete neurale non ricorrente** visto che genera un andamento della domanda più simile all'andamento reale (figure 50 e 56), un tracking signal compreso nell'intervallo +/- 6 (cap.18) al contrario della rete ricorrente (che ha un TS di 7) e valori di MAD, BIAS e ME non troppo peggiori rispetto alla rete ricorrente. Dunque, volendo stilare una classifica si ha:

1. RETE NEURALE MULTISTRATO NON RICORRENTE;
2. RETE NEURALE MULTISTRATO RICORRENTE;
3. MODELLO DI WINTERS;
4. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO.

Infine, prima di concludere è bene accennare come nel metodo statico e nel modello di Winters si abbia un indicatore di Durbin – Watson (cap. 1.8) minore di 2 **a sottolineare una correlazione positiva negli errori** (si tendono ad accumulare errori di sovrastima della domanda). Nella rete neurale non ricorrente si ha invece un indicatore di Durbin – Watson maggiore di 2 (**correlazione negativa degli errori** che sottolinea l'insieme di sovrastime e sottostime) mentre nella rete neurale ricorrente si ha un valore di questo indicatore circa pari a due (errori distribuiti casualmente che non seguono un pattern preciso).

3.4 – PREVISIONI DEI TACCHI ALTI (TA)

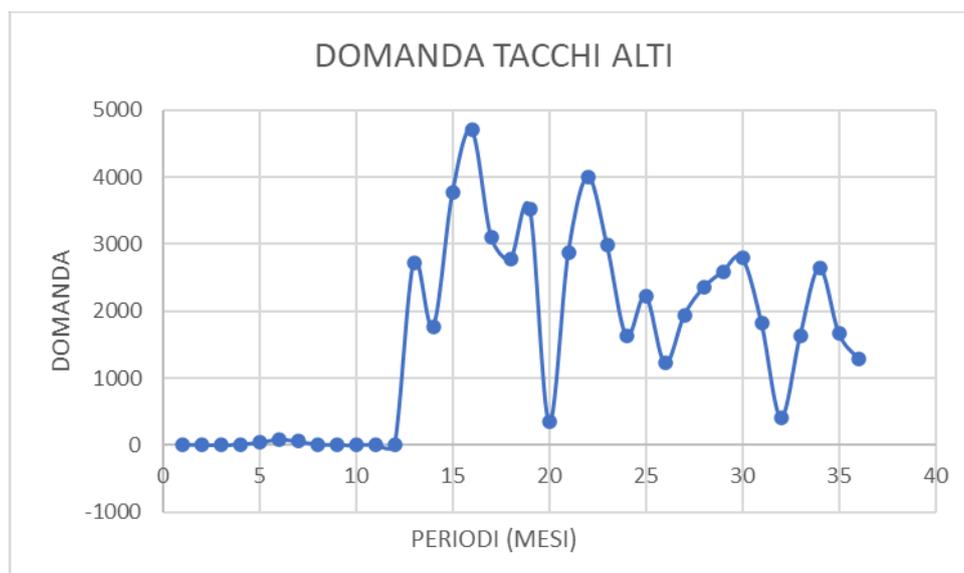


Figura 61: ANDAMENTO DELLA DOMANDA DI TACCHI ALTI

METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO

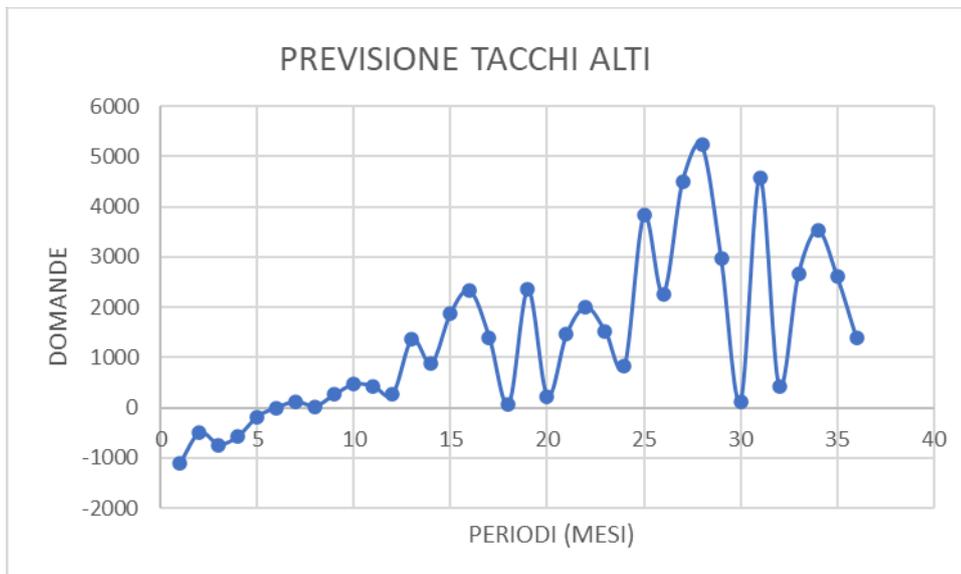


Figura 62: ANDAMENTO DELLA DOMANDA DI TACCHI ALTI SECONDO IL METODO STATICO

ANNO 2019	
MSE	3008441
MAD	1405
BIAS	11522
TS	8
DW	1,58
MAPE	70%
ME	960

Figura 63: INDICATORI TACCHI ALTI METODO STATICO

MODELLO DI WINTERS

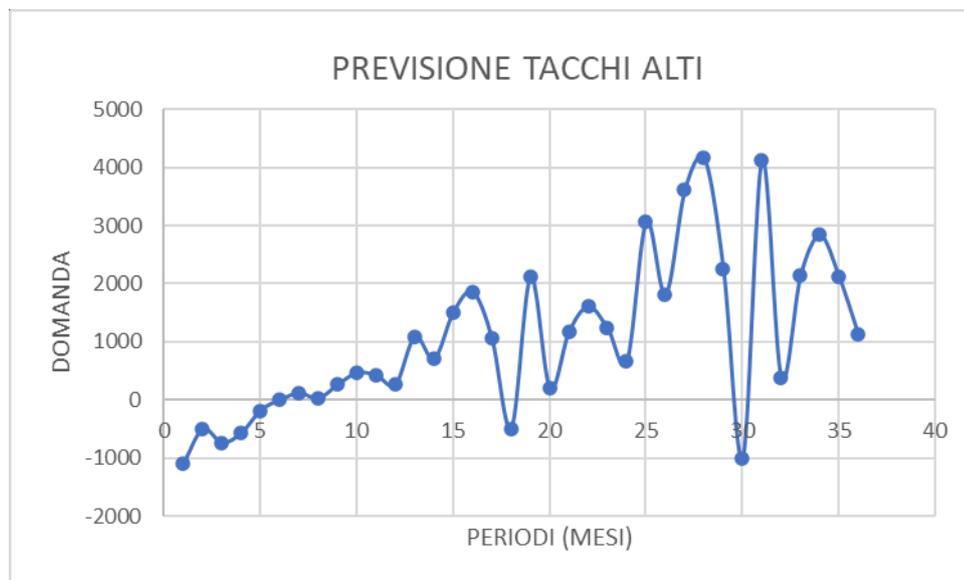


Figura 64: ANDAMENTO DELLA DOMANDA DI TACCHI ALTI SECONDO IL MODELLO DI WINTERS

COEFFICIENTI DI SMORZAMENTO UTILIZZATI: $a = 0,0001$, $b=0,1$ e $\gamma=0,2$.

ANNO 2019	
MSE	2280210
MAD	1054
BIAS	4003
TS	4
DW	2,23
MAPE	51%
ME	334

Figura 65: INDICATORI TACCHI ALTI MODELLO WINTERS

RETE NEURALE MULTISTRATO

Con la rete neurale riportata in figura 42 e 33 epoche (fig. 66) si hanno i seguenti risultati:

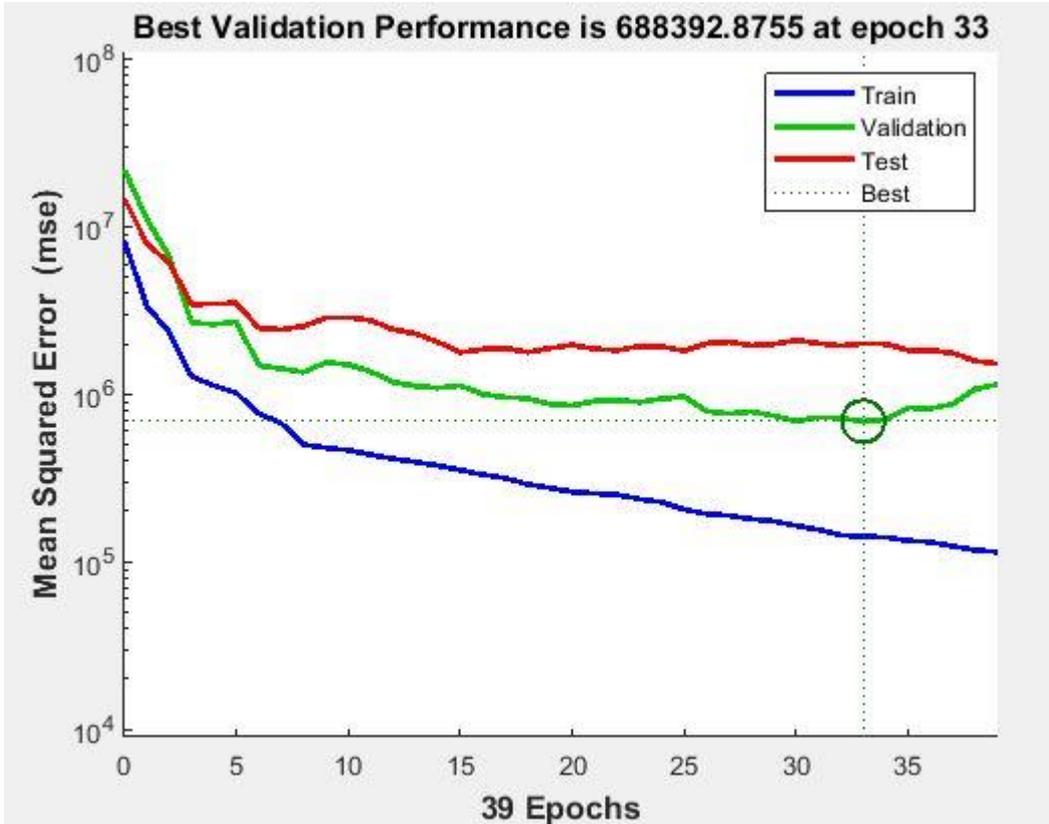


Figura 66: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (TACCHI ALTI)

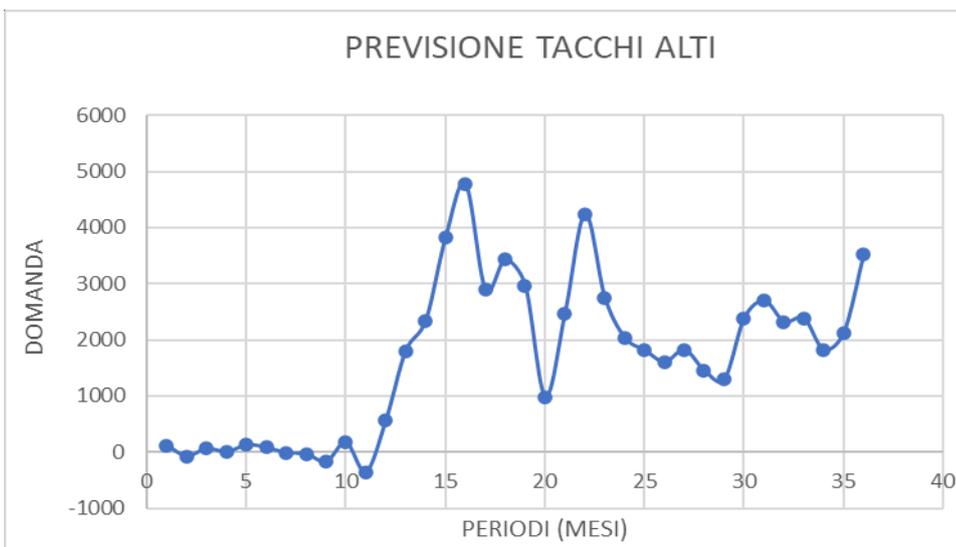


Figura 67: ANDAMENTO DELLA DOMANDA DI TACCHI ALTI SECONDO LA RETE NEURALE MULTISTRATO

ANNO 2019	
MSE	1149026
MAD	880
BIAS	2604
TS	3
DW	0,999
MAPE	78%
ME	217

Figura 68: INDICATORI TACCHI ALTI RETE NEURALE MULTISTRATO

RETE NEURALE MULTISTRATO RICORRENTE

Con la rete neurale ricorrente riportata in figura 46 e 3 epoche (fig. 69) si ha la seguente situazione:

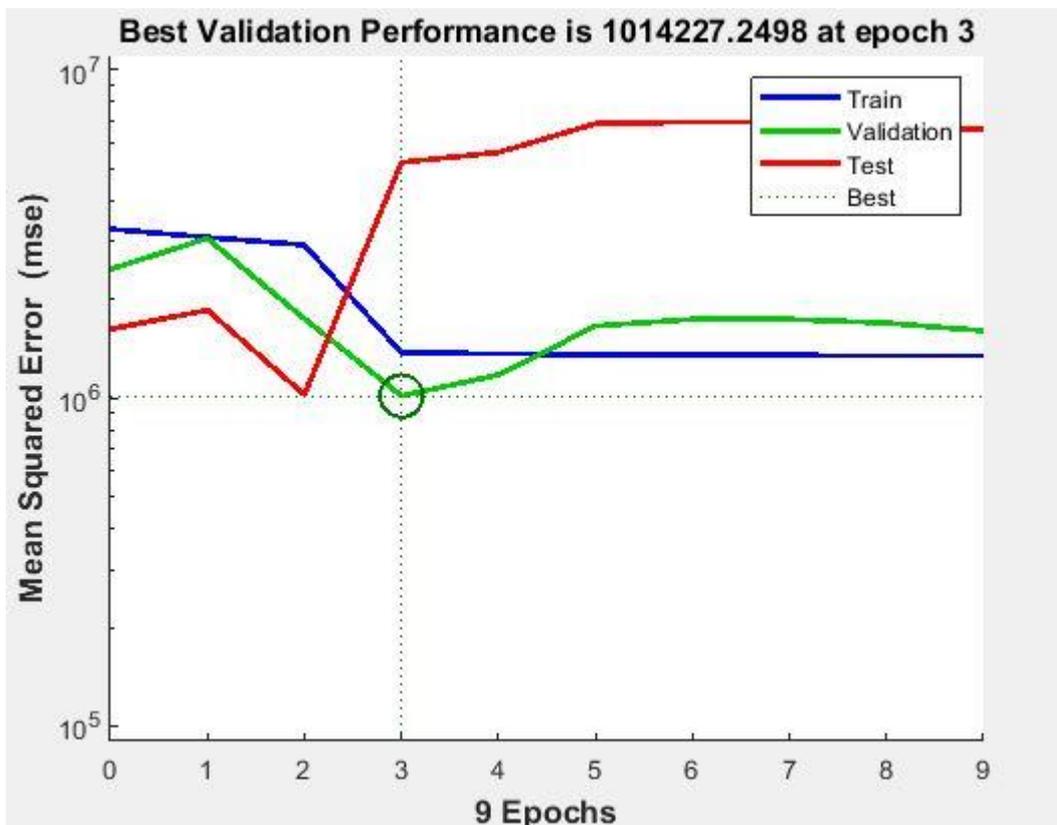


Figura 69: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (TACCHI ALTI)

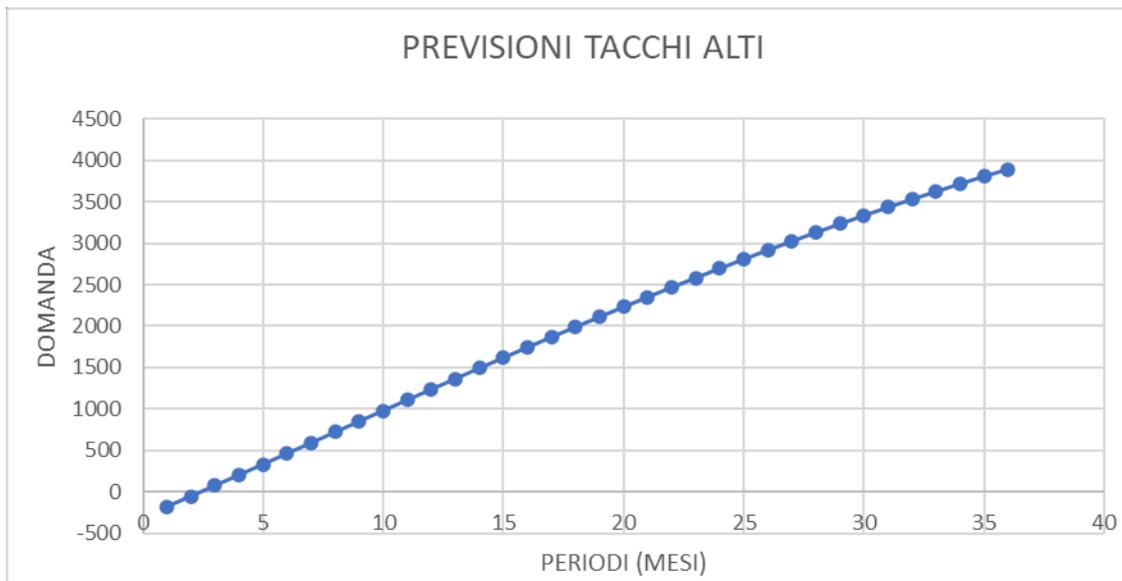


Figura 70: ANDAMENTO DELLA DOMANDA DI TACCHI ALTI SECONDO LA RETE NEURALE MULTISTRATO RICORRENTE

ANNO 2019	
MSE	2863964
MAD	1485
BIAS	17819
TS	12
DW	0,25
MAPE	135%
ME	1485

Figura 71: INDICATORI TACCHI ALTI RETE NEURALE MULTISTRATO RICORRENTE

CONCLUSIONI: QUAL È IL METODO DI PREVISIONE MIGLIORE NEL CASO DEI TACCHI ALTI?

Osservando gli indicatori delle figure 63, 65, 68 e 71 si può notare come il metodo migliore sia il **modello di Winters** visto che ha il MAPE più basso (51%) oltre a un TS compreso tra +/- 6 (cap.1.8). Inoltre, anche i valori di MAD, BIAS e ME sono abbastanza buoni. Il secondo metodo migliore è la rete neurale non ricorrente visto che ha il MAD migliore, un TS compreso tra +/- 6, l'MSE più basso di tutti e un BIAS/ME migliori rispetto a quelli di Winters (probabilmente sono più bassi poiché vi sono stati errori più di sottostima considerando che i due ME e i due BIAS sono positivi). Infine, i due metodi peggiori si sono rivelati rispettivamente il metodo statico e la rete ricorrente visto che hanno generato BIAS e MSE molto elevati (enormi sovrastime di domanda). Dunque, stilando una classifica dei metodi si ottiene:

1. MODELLO DI WINTERS;
2. RETE NEURALE MULTISTRATO NON RICORRENTE;
3. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO;
4. RETE NEURALE MULTISTRATO RICORRENTE.

Infine, si può notare come gli indicatori di Durbin – Watson siano **tutti minori di due** (correlazione positiva degli errori) **tranne nel caso del modello di Winters** (dove esso è maggiore di 2 ed indica una **correlazione negativa degli errori**). Infatti, nel modello di Winters abbiamo un'alternanza di sovrastime e sottostime (le prime sono però molto più numericamente di valore maggiore). Inoltre, nella rete neurale non ricorrente pur avendo una **correlazione positiva degli errori** che in questo caso è legata alle molte sottostime che la rete neurale genera (sono molto frequenti) si ha che le sovrastime restano comunque maggiori delle sottostime in termini di valore totale. Nonostante ciò, l'enorme frequenza delle sottostime fa sì che si abbassino molto BIAS e ME.

3.5 – PREVISIONI DEI TACCHI BASSI (TB)

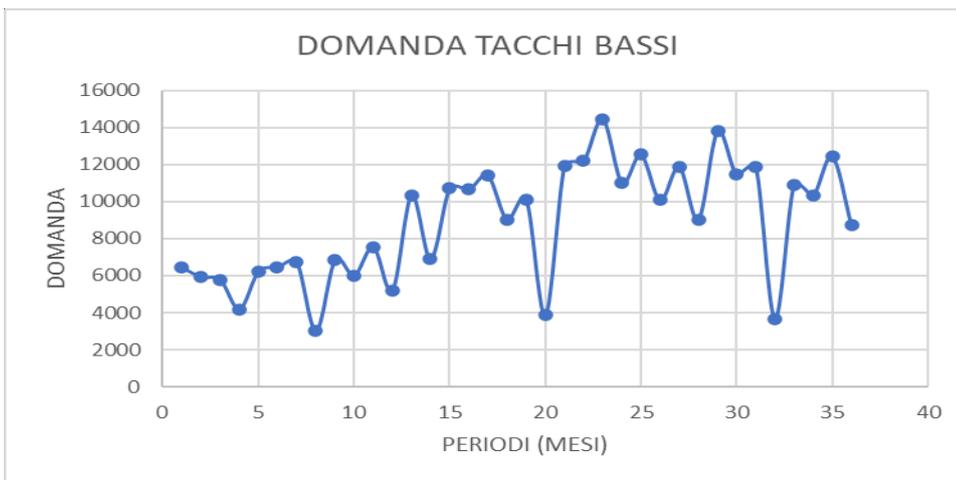


Figura 72: ANDAMENTO DELLA DOMANDA DI TACCHI BASSI

METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO

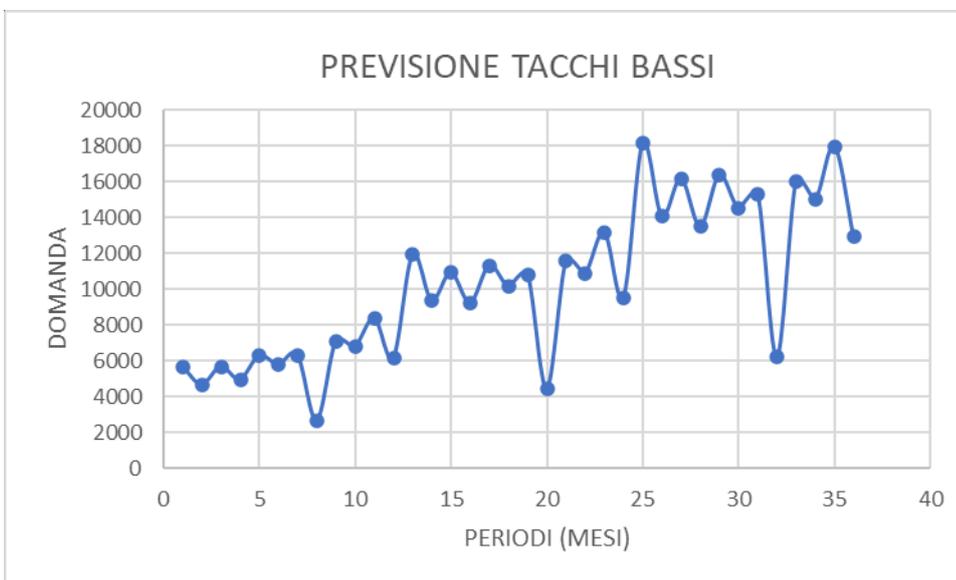


Figura 73: ANDAMENTO DELLA DOMANDA DI TACCHI BASSI SECONDO IL METODO STATICO

ANNO 2019	
MSE	17856331
MAD	4104
BIAS	49247
TS	12
DW	0,079
MAPE	37%
ME	4104

Figura 74: INDICATORI TACCHI BASSI METODO STATICO

MODELLO DI WINTERS

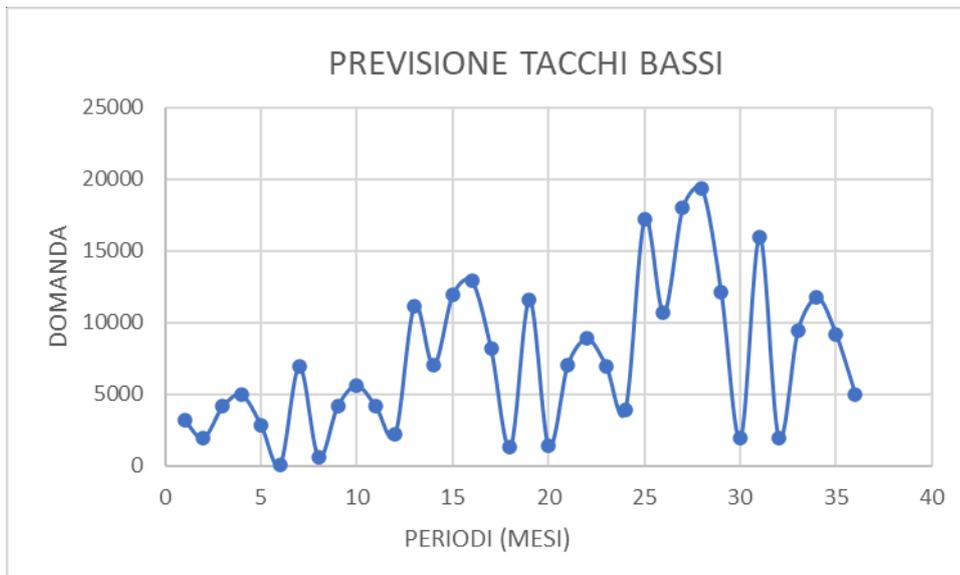


Figura 75: ANDAMENTO DELLA DOMANDA DI TACCHI BASSI SECONDO IL MODELLO DI WINTERS

COEFFICIENTI DI SMORZAMENTO UTILIZZATI: $\alpha = 0,01$, $\beta=0,01$ e $\gamma=0,1$.

ANNO 2019	
MSE	25597935
MAD	4041
BIAS	5742
TS	1,42
DW	1,68
MAPE	40%
ME	478

Figura 76: INDICATORI TACCHI BASSI MODELLO DI WINTERS

RETE NEURALE MULTISTRATO

Sfruttando la rete neurale riportata in figura 42 e 21 epoche (fig.77) si ha:

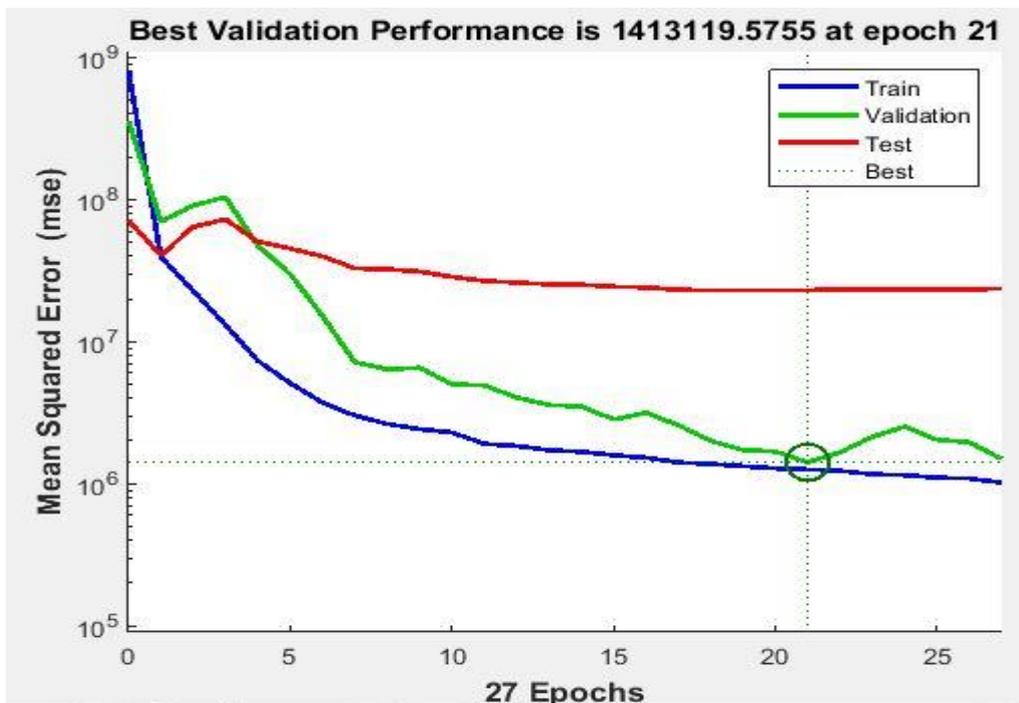


Figura 77: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (TACCHI BASSI)



Figura 78: ANDAMENTO DELLA DOMANDA DI TACCHI BASSI SECONDO LA RETE NEURALE Mulsitrato

ANNO 2019	
MSE	10369894
MAD	2128
BIAS	3202
TS	2
DW	1,9
MAPE	33%
ME	267

Figura 79: INDICATORI TACCHI BASSI RETE NEURALE MULTISTRATO

RETE NEURALE MULTISTRATO RICORRENTE

Applicando la rete neurale multistrato della **figura 46** (fig. 80) e **4 epoche** si ottiene:

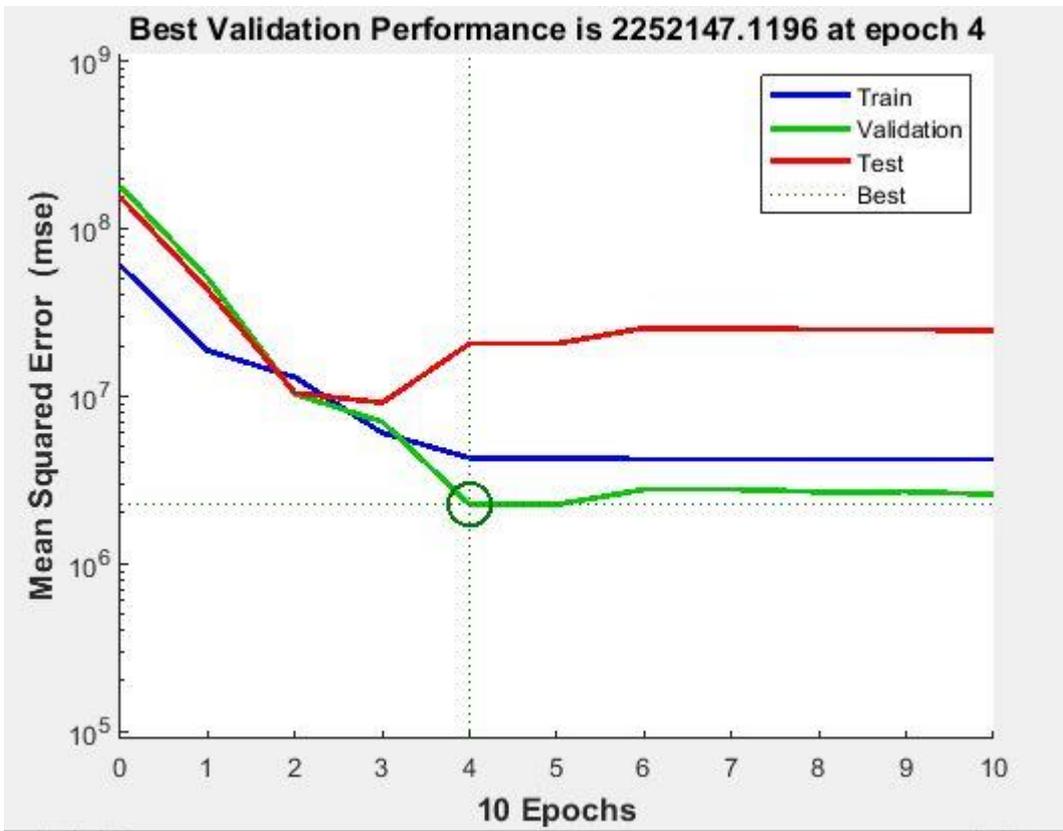


Figura 80: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (TACCHI BASSI)

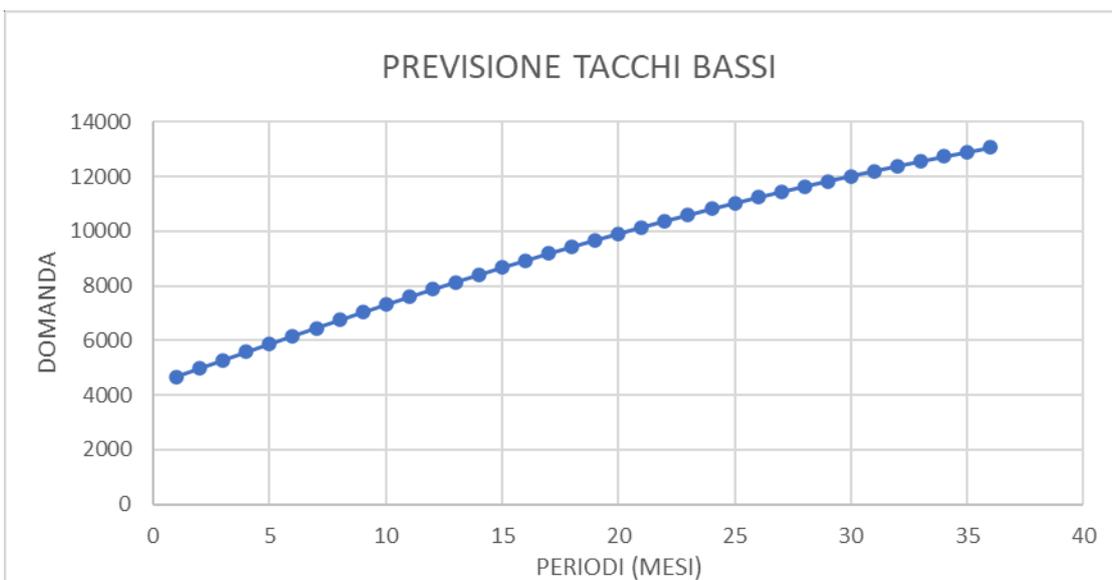


Figura 81: ANDAMENTO DELLA DOMANDA DI TACCHI BASSI SECONDO LA RETE NEURALE MULTISTRATO RICORRENTE

ANNO 2019	
MSE	9807170
MAD	2168
BIAS	18174
TS	8
DW	1,58
MAPE	34%
ME	1514

Figura 82: INDICATORI TACCHI BASSI RETE NEURALE MULTISTRATO RICORRENTE

CONCLUSIONI: QUAL È IL METODO DI PREVISIONE MIGLIORE NEL CASO DEI TACCHI BASSI?

Vedendo gli indicatori delle figure 74, 76, 79 e 82 si nota che il metodo migliore sia la **rete neurale non ricorrente** visto che ha un buon ME (267), BIAS E MAD BIAS più bassi (3201 e 33%) e un TS compreso tra +/- 6 (tutti i metodi tranne quello statico e la rete ricorrente hanno un TS compreso tra +/- 6).

Per quanto riguarda invece gli altri metodi si ha rispettivamente come secondo metodo migliore quello di Winters visto che ha un buon ME e un BIAS nettamente migliore rispetto agli altri metodi (a parte la rete non ricorrente). Come metodo peggiore si ha invece il metodo statico visto che non ha appunto un TS compreso tra +/- 6, il BIAS peggiore e un grandissimo ME (4104).

Facendo dunque una classifica dei metodi si ha:

1. RETE NEURALE MULTISTRATO NON RICORRENTE;
2. MODELLO DI WINTERS;
3. RETE NEURALE MULTISTRATO RICORRENTE;
4. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO.

Infine, è opportuno notare come l'indicatore di Durbin - Watson nella rete non ricorrente sia molto vicino a due e dia dunque origine a errori di sovrastima alternati a errori di sottostima di tipo casuale (non si evince un vero e proprio pattern). Negli altri metodi si ha invece un indicatore di Durbin - Watson minore di due (correlazione positiva degli errori).

3.6 – PREVISIONI DEGLI INSERTI (IS)

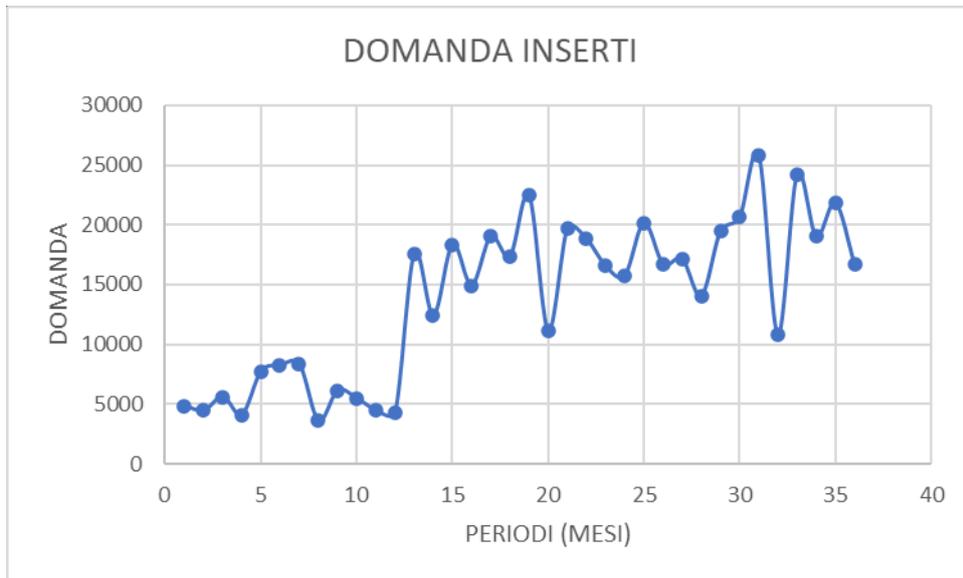


Figura 83 ANDAMENTO DELLA DOMANDA DI INSERTI

METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO

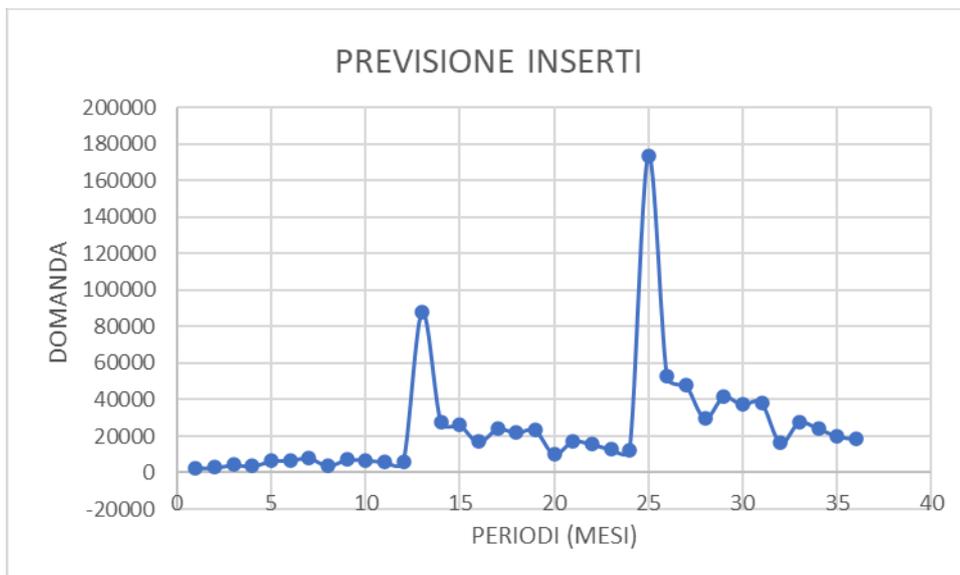


Figura 84: ANDAMENTO DELLA DOMANDA DI INSERTI SECONDO IL METODO STATICO

ANNO 2019	
MSE	2247508535
MAD	25433
BIAS	301757
TS	12
DW	0,53
MAPE	136%
ME	25146

Figura 85: INDICATORI INSERTI METODO STATICO

MODELLO DI WINTERS

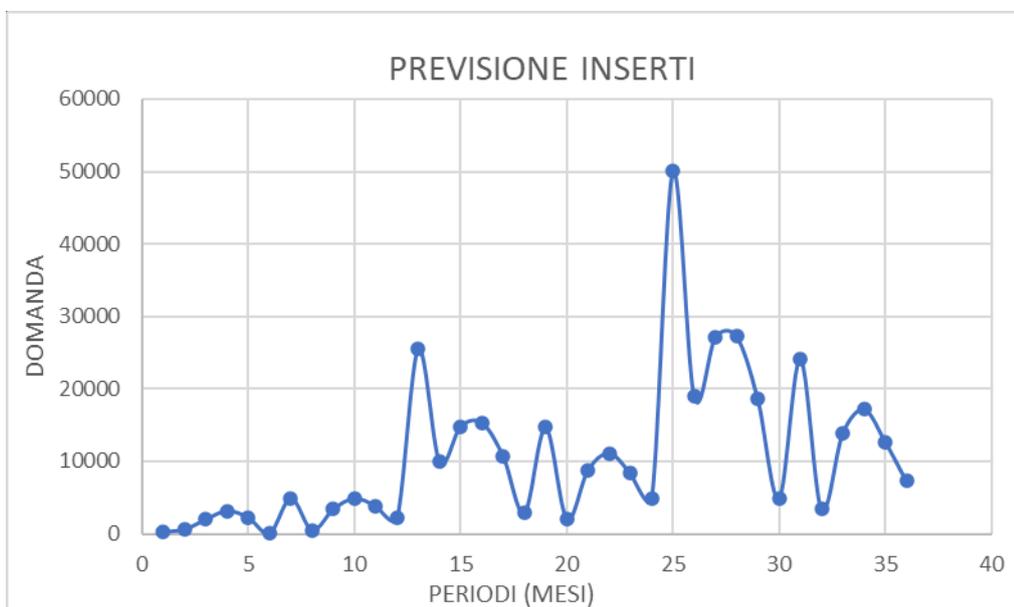


Figura 86: ANDAMENTO DELLA DOMANDA DI INSERTI SECONDO IL MODELLO DI WINTERS

COEFFICIENTI DI SMORZAMENTO UTILIZZATI: $a = 0,01$, $b=0,01$ e $\gamma=0,1$.

ANNO 2019	
MSE	146963709
MAD	9317
BIAS	-1080
TS	-0,12
DW	0,92
MAPE	39%
ME	-90

Figura 87: INDICATORI INSERTI MODELLO WINTERS

RETE NEURALE MULTISTRATO

Utilizzando la rete neurale rappresentata in **figura 42** e **17 epoche** (fig. 88) si ottiene:

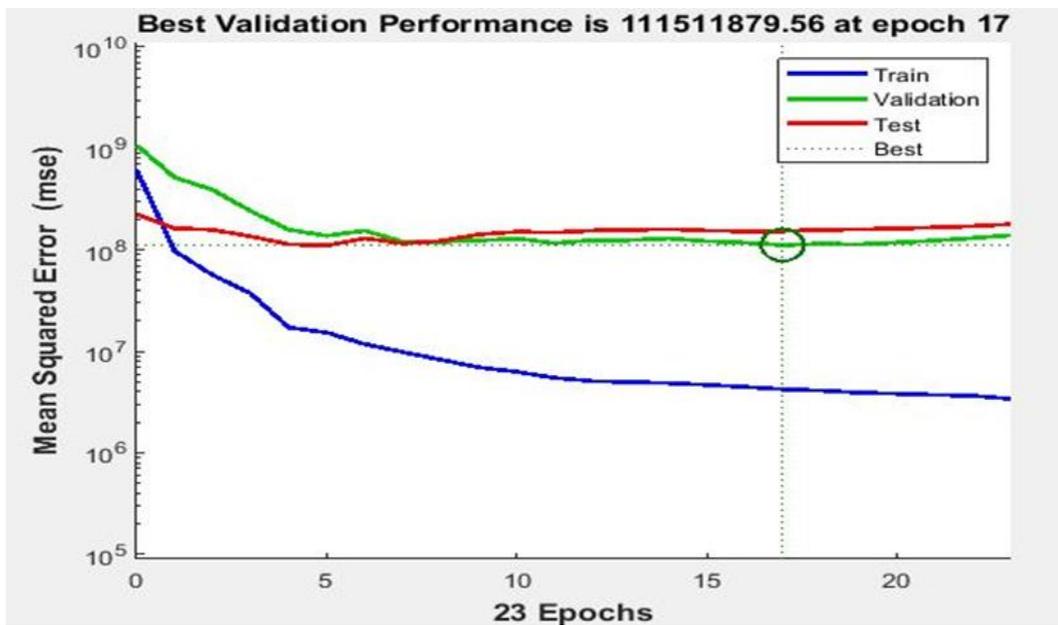


Figura 88: NUMERO DI EPOCHE RETE NEURALE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (INSERTI)



Figura 89: ANDAMENTO DELLA DOMANDA DI INSERTI SECONDO LA RETE NEURALE MULTISTRATO

ANNO 2019	
MSE	110529086
MAD	8983
BIAS	102783
TS	11
DW	0,34
MAPE	53%
ME	8565

Figura 90: INDICATORI INSERTI RETE NEURALE MULTISTRATO

RETE NEURALE MULTISTRATO RICORRENTE

Con la rete neurale ricorrente in figura 46 e 2 epoche (fig. 91) si ha:

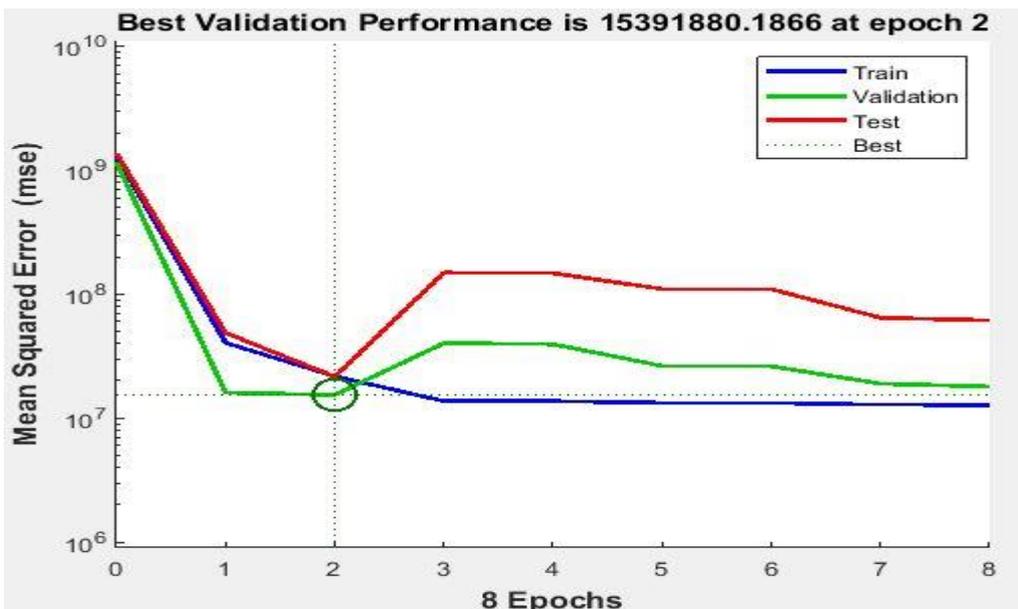


Figura 91: NUMERO DI EPOCHE RETE NEURALE RICORRENTE SECONDO L'ALGORITMO DEL GRADIENTE CONIUGATO SCALATO (INSERTI)

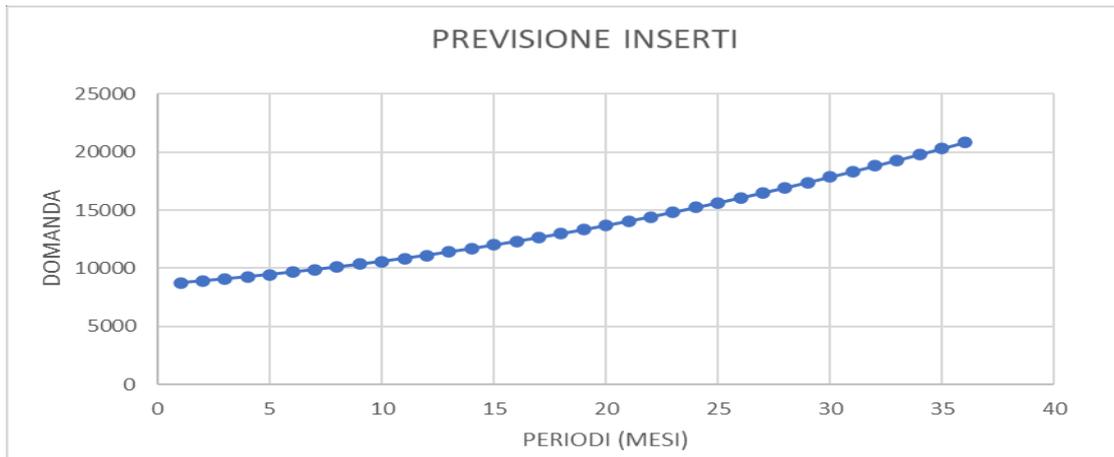


Figura 92: ANDAMENTO DELLA DOMANDA DI INSERTI SECONDO LA RETE NEURALE MULTISTRATO RICORRENTE

ANNO 2019	
MSE	17142339
MAD	3366
BIAS	-8853
TS	-3
DW	2,68
MAPE	20%
ME	-738

Figura 93: INDICATORI INSERTI RETE NEURALE MULTISTRATO RICORRENTE

CONCLUSIONI: QUAL È IL METODO DI PREVISIONE MIGLIORE NEL CASO DEGLI INSERTI

Osservando gli indicatori in figura 85, 87, 90 e 93 si può notare come il metodo migliore sia, per quanto concerne le previsioni di domanda degli inserti, il **modello di Winters**. Infatti, pur non avendo il MSE e il MAPE con i valori più bassi, si ha un ME pari a -90 e un TS compreso nell'intervallo +/-6. Inoltre, il modello di Winters genera un BIAS pari a -1080 (sottostima della domanda) mentre il secondo metodo migliore (avente il migliore MAPE), ovvero la rete neurale ricorrente, dà luogo anch'esso a un TS compreso tra +/-6 e, similmente del metodo migliore, a una sovrastima della domanda (ME e BIAS molto negativi) che comunque è molto superiore a quella generata dal modello di Winters. Il metodo peggiore invece si è rivelato essere quello statico a causa di un MAPE e un MAD molto alti (136% e 25433) oltre a un TS di 12.

Stilando dunque una classifica dei metodi si ha:

1. MODELLO DI WINTERS;
2. RETE NEURALE MULTISTRATO RICORRENTE;
3. RETE NEURALE MULTISTRATO NON RICORRENTE;
4. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO.

Infine, è bene notare come quasi tutti i metodi abbiano valori dell'indicatore di Durbin – Watson **minori di 2** e che sono dunque indice di una **correlazione positiva degli errori** (si commettono o frequenti sovrastime o frequenti sottostime). Solo nella rete neurale ricorrente si ha un indicatore di Durbin – Watson maggiore di due (**correlazione negativa** indice di un'alternanza di sovrastime e sottostime).

CONSIDERAZIONI FINALI

Analizzando i vari metodi utilizzati nell'effettuazione delle previsioni di domanda per i vari componenti della Santoni e in particolare le varie **classifiche** relative ai vari metodi si può dunque affermare come il metodo migliore sembri essere quello di Winters visto che esso risulta essere primo in classifica due volte su cinque (nel caso dei tacchi alti e degli inserti) , secondo in classifica due volte (sottopiedi e tacchi bassi) e terzo solo nel caso dei fondi. Il secondo metodo migliore risulta invece essere **la rete neurale ricorrente** (pur generando previsioni che non mettono bene in evidenza l'andamento oscillatorio della domanda) visto che è primo in classifica nel caso dei sottopiedi, terzo per una volta (tacchi bassi), secondo per due volte (fondi e inserti) e ultimo nel caso dei tacchi alti. I due metodi peggiori risultano invece essere rispettivamente **la rete neurale multistrato non ricorrente** e **il metodo statico con destagionalizzazione** con quest'ultimo che però ha performato nettamente peggio rispetto alla rete non ricorrente (mentre la rete neurale non ricorrente risulta essere prima per ben 2 volte, seconda per una volta, terza in un'occasione e quarta in un'ulteriore occasione si ha che il metodo statico si è classificato sempre quarto o terzo).

La **classifica generale dei metodi** risulta dunque essere:

1. MODELLO DI WINTERS;
2. RETE NEURALE MULTISTRATO RICORRENTE;
3. RETE NEURALE MULTISTRATO NON RICORRENTE;

4. METODO STATICO CON DESTAGIONALIZZAZIONE A MODELLO MISTO.

Dopo aver stilato questa classifica va però detto che nonostante la rete neurale multistrato ricorrente si sia rivelata essere la seconda metodologia migliore per effettuare le previsioni di domanda essa risulta essere particolarmente **complessa** da utilizzare (bisogna scegliere il giusto numero di hidden layers, le giuste funzioni di attivazione, il giusto algoritmo di minimizzazione dell'MSE, fare vari tentativi, ...) Ciò rafforza la preferenza del metodo di **Winters** rispetto alla rete neurale multistrato (bisogna solo fare molte prove con coefficienti di smorzamento). Inoltre, come già affermato nei capitoli precedenti, il modello di Winters è **adattativo** ed è dunque in grado di aggiornare le proprie previsioni sulla base delle domande effettive andando al più a variare i vari coefficienti di smorzamento nel caso fosse necessario (la rete neurale andrebbe invece addestrata nuovamente sulla base dei nuovi dati di domanda). Dunque, in conclusione si può dire che si potrebbe utilizzare una **rete neurale multistrato ricorrente con buoni risultati** ma **nel caso essa diventasse troppo complicata da implementare sarebbe opportuno provare ad utilizzare il metodo di Winters.**

Ovviamente, i metodi appena discussi sono solo alcuni di quelli introdotti nel capitolo uno e non sono in grado, essendo metodi matematici, di prevedere eventi imprevedibili (azioni di concorrenti, eventuali problemi di fornitori, etc.) e dovrebbero dunque magari essere coadiuvati da **metodi qualitativi** (capitolo 1), in particolare opinioni di esperti.

APPENDICE, BIBLIOGRAFIA E SITOGRAFIA

APPENDICE

```
trainFcn = 'trainscg';  
hiddenLayer1Size = 30;  
hiddenLayer2Size = 30;  
net = fitnet([hiddenLayer1Size hiddenLayer2Size], trainFcn);  
[trainInd,valInd,testInd] = divideblock(36,0.4,0.26,0.34);  
net.divideFcn='divideblock';  
net=train(net,PERIODI,SP);  
RESULTS=net(PERIODI);
```

APPENDICE, FIGURA 1: CODICE MATLAB RETE NEURALE MULTISTRATO NON RICORRENTE (ESEMPIO DEI SOTTOPIEDI)

```

trainFcn = 'trainscg';
hiddenLayer1Size = 30;
hiddenLayer2Size = 30;
net = layrecnet(1:1,[hiddenLayer1Size hiddenLayer2Size], trainFcn);
[trainInd,valInd,testInd] = divideblock(36,0.4,0.26,0.34);
net.divideFcn='divideblock';
net=train(net,PERIODI,SP);
RESULTS=net(PERIODI);

```

APPENDICE, FIGURA 2: CODICE MATLAB RETE NEURALE MULTISTRATO RICORRENTE (ESEMPIO DEI SOTTOPIEDI)

BIBLIOGRAFIA E SITOGRAFIA

- Slides del corso “Progettazione e Gestione della Catena Logistica”, Prof. Maurizio Bevilacqua (in particolare, figura 5);
- slides del corso “Programmazione e Controllo della Produzione” tratte da: Filippo Gabrielli, Appunti di Programmazione e Controllo della Produzione, Pitagora Editrice, Bologna 2006;
- slides del Corso Gestione dei Progetti e degli Impianti Industriali, Prof. Filippo Emanuele Ciarapica;
- slides del corso “Analisi e controllo di Sistemi Complessi, Prof.ssa. Sabrina Iarlori;
- slides del corso “Tecnologie per i Sistemi Informativi, Prof. Emanuele Storti (in particolare, figura 18);
- slides del corso “Gestione Industriale della Qualità”, Prof. Carmine Dazj;
- https://cdm.unimore.it/home/dimec/melloni.riccardo/DL_02_Previsione%20della%20domanda.pdf;
- https://it.wikipedia.org/wiki/Metodo_Delphi;
- (figura 4) [https://www.lokad.com/it/ciclo-di-vita-del-prodotto-\(pianificazione-inventario\)](https://www.lokad.com/it/ciclo-di-vita-del-prodotto-(pianificazione-inventario));
- https://it.wikipedia.org/wiki/Regressione_lineare (in particolare, figura 6);
- https://it.wikipedia.org/wiki/Regressione_nonlineare;

- https://it.wikipedia.org/wiki/Rete_neurale_artificiale;
- <https://it.wikipedia.org/wiki/Percettrone;>
- <https://www.developersmaggioli.it/blog/le-reti-neurali-ricorrenti/;>
- https://en.wikipedia.org/wiki/Training,_validation,_and_test_sets;
- <https://netai.it/guida-rapida-alle-funzioni-di-attivazione-nel-deep-learning/#page-content;>
- <https://stackoverflow.com/questions/2480650/what-is-the-role-of-the-bias-in-neural-networks;>
- [https://it.wikipedia.org/wiki/Gradiente_\(funzione\);](https://it.wikipedia.org/wiki/Gradiente_(funzione);)
- https://it.wikipedia.org/wiki/Discesa_del_gradiente;
- https://it.wikipedia.org/wiki/Distribuzione_normale;
- (figura 35) <http://docenti.unimc.it/luisa.scaccia/teaching/2018/19147/files/lezione-11;>
- <https://www.massaboutique.com/the-brand/santoni/#:~:text=Santoni%20%C3%A8%20sinonimo%20di%20scarpa,calzature%20per%20uomo%20nel%20mondo;>
- <https://forbes.it/2019/02/01/rinascimento-calzature-italiane-stile-moda/;>
- <https://www.santonishoes.com/it/about-santoni;>
- rapporto tecnico della Santoni S.p.a;
- <https://www.tecnicacalzaturiera.it/2018/06/06/il-sottopiede-componente-fondamentale-della-scarpa/;>
- <https://www.ilgergo.com/comit/produzione.html;>
- <https://mvcomfort.com/fussbett-per-calzature/;>

- <https://www.mathworks.com/matlabcentral/answers/445848-how-to-create-a-fitnet-neural-network-with-multiple-hidden-layers>;
- <https://www.mathworks.com/help/deeplearning/ref/layrechnet.html>;
- <https://www.mathworks.com/help/deeplearning/ref/divideblock.html>;
- <https://www.mathworks.com/help/deeplearning/ref/fitnet.html>.

Software utilizzati per effettuare le previsioni di domanda: Microsoft Excel 2016 e Matlab 2021.

RINGRAZIAMENTI

Desidererei ringraziare in primis il mio relatore, il Ch.mo Prof. Filippo Emanuele Ciarapica, per avermi seguito durante tutto il mio lavoro di tesi e avermi in particolare elargito numerosi consigli e suggerimenti che sono stati preziosissimi. Vorrei inoltre ringraziare la Santoni S.p.a per l'opportunità di tesi, per avermi fornito tutti i dati necessari per l'effettuazione delle previsioni di domanda e per avermi anche permesso di consultare un rapporto tecnico sulla loro azienda senza il quale non mi sarebbe stato possibile comprendere il processo produttivo delle loro calzature e tutti i codici identificativi dei vari componenti. Un ringraziamento speciale va inoltre al Prof. Emanuele Storti e al Dott. Giovanni Mazzuto che mi hanno fornito numerosi suggerimenti e consigli riguardo la parte del data mining e delle reti neurali.

Un sincero grazie va inoltre ai miei genitori che mi hanno supportato e incoraggiato durante i miei studi e durante tutta la mia vita e senza i quali non avrei mai raggiunto i miei traguardi.

Ringrazio inoltre tutte le meravigliose persone che mi hanno voluto bene e che mi hanno sostenuto durante la mia vita come i miei amici, compagni di scuola, professori, coinquilini, ...

Vorrei inoltre concludere la tesi di laurea con una delle mie frasi preferite e che spero mi ispiri nel mondo del lavoro che sto affrontare:

“Stay hungry, stay foolish” (siate affamati, siate folli)

Steve Jobs

