



**UNIVERSITÀ
DI PAVIA**

**Dipartimento di Scienze Economiche Aziendali
Corso di Laurea in Economia e Gestione delle Imprese**

**INTELLIGENZA ARTIFICIALE NEL CASH
MANAGEMENT:
COSTI, BENEFICI E VALORE STRATEGICO NELLA
TRANSIZIONE DIGITALE D'IMPRESA**

Relatore:

Chiar.mo Prof. Alessandro Zardini

**Tesi di Laurea di
Christian Cunsolo
Matr. n. 542702**

Anno Accademico 2025-2026

INDICE

INTRODUZIONE	1
CAPITOLO 1 - FONDAMENTI ED EVOLUZIONE DEL CASH MANAGEMENT ..	2
1.1 Il Cash Management nella Gestione Finanziaria d'Impresa	2
1.1.1 Definizione e perimetro funzionale	2
1.1.2 Le metriche di performance del cash management	6
1.1.3 Il valore strategico della liquidità aziendale	11
1.2 L'Evoluzione Storica del Cash Management: Da Funzione Operativa a Partner Strategico	16
1.2.1 L'era pre-digitale (1980-2000): Gestione manuale e processi cartacei	17
1.2.2 La digitalizzazione di base (2000-2015): ERP e Business Intelligence	20
1.2.3 La rivoluzione AI (2015-oggi): Cash management intelligente e predittivo	26
1.3 L'Intelligenza Artificiale nel Cash Management: Tassonomia Applicativa	31
1.3.1 Fondamenti di AI e Machine Learning per manager	31
CAPITOLO 2 - L'ANALISI ECONOMICO-GESTIONALE: COSTI, BENEFICI E ROI DELL'IA	39
2.1 Il Total Cost of Ownership: Anatomia dell'Investimento	39
2.1.1 Framework Analitico TCO per Soluzioni AI	39
2.1.2 Costi Diretti Tecnologici	42
2.1.3 Costi Organizzativi e Change Management	46
2.1.4 Costi di Integrazione Dati e Sistemi Legacy	49
2.2 I Benefici dell'AI: Creazione di Valore Multi-Dimensionale	51
2.2.1 Framework di Classificazione dei Benefici	52
2.2.2 Benefici Automational: Efficienza Operativa	53
2.2.3 Benefici Informational: Qualità Decisionale Superiore	56
2.2.4 Benefici Transformational: Ridefinizione Organizzativa	59
2.2.5 Benefici Financial: Impatto Bottom-Line	61
2.3 Il Ritorno sull'Investimento: Evidenze Empiriche e Determinanti del Successo	63
2.3.1 Metodologia Sintesi ROI	64
2.3.2 Payback Period e Net Present Value	65
2.3.3 Determinanti del ROI: Analisi fattori	67
2.4 Framework Decisionale per il CFO: Valutare l'Investimento in AI	70
2.4.1 L'Evoluzione del Mandato del CFO	70
2.4.2 Valutazione del Rischio: Oltre il NPV Positivo	71
2.4.3 Il Dilemma Sourcing: Build vs. Buy	73
CAPITOLO 3 - ANALISI COMPARATA DEI MODELLI: PRE-AI VS POST-AI	75
3.1 Il Cash Forecasting Prima dell'IA: Metodologie Tradizionali	75

3.1.1	<i>Approcci statistici classici</i>	76
3.1.2	<i>Il ruolo del giudizio esperto (Expert Judgment)</i>	81
3.1.3	<i>Limiti strutturali dei metodi tradizionali</i>	84
3.2	<i>Il Cash Forecasting con l'IA: Metodologie Moderne</i>	88
3.2.1	<i>Machine Learning: Algoritmi e architetture</i>	89
3.2.2	<i>Automazione e integrazione real-time</i>	95
3.3	<i>Confronto Operativo: Accuratezza, Efficienza e Decisional Value</i>	100
3.3.1	<i>Accuratezza previsionale: Analisi comparativa</i>	101
3.3.2	<i>Efficienza operativa: Time to forecast e scalabilità</i>	103
3.3.3	<i>Decisional Value: Dalla Previsione all'Azione</i>	105
	CONCLUSIONE	111
	BIBLIOGRAFIA	113

INTRODUZIONE

Il cash management rappresenta una funzione strategica per la governance finanziaria d'impresa, in quanto garantisce la disponibilità di liquidità necessaria a sostenere l'operatività corrente, ottimizzare l'impiego delle risorse e preservare la solidità finanziaria nel tempo. Le decisioni in questo ambito si fondano in gran parte sulla qualità delle previsioni dei flussi di cassa, il cui grado di accuratezza incide direttamente sulla capacità dell'impresa di cogliere opportunità strategiche. Storicamente, tali previsioni venivano elaborate attraverso modelli statistici a serie storiche i quali, pur rappresentando un progresso rispetto ai processi manuali, presentavano limiti strutturali in termini di scalabilità e capacità di incorporare variabili esogene. L'avvento dell'intelligenza artificiale e del machine learning ha ridefinito questo paradigma, introducendo architetture predittive capaci di apprendere autonomamente relazioni non lineari nei dati e di ridurre consistentemente l'errore previsionale medio.

Il presente lavoro si pone l'obiettivo di analizzare questa trasformazione nelle sue dimensioni tecnologiche, economiche e organizzative. Nel Capitolo 1 vengono definiti il perimetro funzionale del cash management e le principali tappe della sua evoluzione storica. Il Capitolo 2 sviluppa un'analisi economica dell'investimento in soluzioni di intelligenza artificiale attraverso framework di TCO e ROI, approfondendo inoltre i processi di adozione tecnologica e le dinamiche di change management che accompagnano la trasformazione della funzione di tesoreria. Il Capitolo 3 approfondisce le metodologie di cash forecasting, confrontando gli approcci tradizionali con quelli basati sull'IA: tra questi ultimi, vengono analizzate le reti neurali ricorrenti LSTM, i modelli di gradient boosting XGBoost e gli approcci ensemble che combinano i due metodi.

CAPITOLO 1 - FONDAMENTI ED EVOLUZIONE DEL CASH MANAGEMENT

1.1 Il Cash Management nella Gestione Finanziaria d'Impresa

Questo primo paragrafo ha l'obiettivo di inquadrare la funzione del *cash management* all'interno della più ampia struttura di governo finanziario dell'impresa. Prima di analizzare l'impatto delle nuove tecnologie, è infatti necessario definire il perimetro d'azione tradizionale di tale disciplina, esaminare i principali indicatori (operativi, finanziari e strategici) utilizzati per misurarne le performance ed infine, comprendere il valore autonomo che una gestione ottimizzata della liquidità assume nell'attuale contesto competitivo.

1.1.1 Definizione e perimetro funzionale

Nella letteratura economico-aziendale, il concetto di *cash management* ha attraversato una traiettoria evolutiva che ne ha progressivamente ampliato tanto il perimetro operativo quanto la valenza strategica, trasformandolo da funzione di supporto amministrativo a pilastro della governance finanziaria d'impresa. Comprendere questa evoluzione è il presupposto indispensabile comprendere le ragioni per cui le innovazioni tecnologiche che oggi ridisegnano la funzione, e in particolare l'applicazione dell'intelligenza artificiale ai processi di tesoreria, non rappresentino una semplice automazione di compiti routinari, bensì una trasformazione paradigmatica del modo in cui l'impresa governa una delle sue risorse più critiche.

In senso stretto e tradizionale, il cash management definisce l'insieme delle politiche, dei processi e degli strumenti finalizzati alla gestione ottimale delle disponibilità liquide aziendali, con l'obiettivo di far fronte tempestivamente alle obbligazioni dell'impresa, cercando di ottimizzare l'impiego di risorse altrimenti latenti o non remunerate. Questa definizione, tuttavia, rischia di limitare il cash management a un ruolo puramente difensivo, ovvero evitare che l'impresa vada in crisi di liquidità, trascurando la sua importanza nel trasformare la cassa

disponibile in un reale vantaggio competitivo. Adottando una prospettiva più contemporanea, esso si configura infatti come una funzione trasversale all'intera gestione finanziaria, capace di influenzare in modo determinante sia la sostenibilità operativa nel breve periodo, sia la creazione di valore nel medio-lungo termine¹.

Prima di procedere, è necessario chiarire una distinzione concettuale che la prassi tende spesso a trascurare, quella tra **cash management** e **treasury management**.

Il **treasury management** comprende un insieme di attività più esteso, che abbraccia la gestione del rischio finanziario, la politica di finanziamento e di struttura del capitale, la gestione strategica dei rapporti con il sistema bancario e l'ottimizzazione del portafoglio di investimenti finanziari.

All'interno dell'insieme di attività del treasury management, un suo sottoinsieme è rappresentato dal **cash management**, il quale costituisce il nucleo operativo e tattico. Il suo raggio d'azione si focalizza sulla gestione dei flussi monetari (incassi e pagamenti), sul monitoraggio costante della liquidità disponibile (*cash position*) e sull'attività vitale di previsione dei fabbisogni futuri, ovvero il *cash forecasting*. A livello organizzativo, nelle imprese di medie e grandi dimensioni, le due funzioni assumono ruoli ben distinti all'interno della Direzione Finanziaria. Il cash manager è responsabile della liquidità operativa quotidiana, mentre il tesoriere è chiamato a presidiare i rischi finanziari strutturali e le relazioni con i mercati dei capitali. Pur riportando entrambe direttamente al Chief Financial Officer, esse governano la finanza d'impresa operando con orizzonti temporali, strumenti e metriche di riferimento profondamente differenti².

Chiarito che cosa sia il cash management a livello concettuale, è possibile adesso identificare quali siano gli **obiettivi fondamentali** che orientano la funzione di cash management, i quali si intrecciano in un sistema di relazioni reciproche che rende la funzione un organismo di gestione integrata e non una sommatoria di compiti distinti.

¹ Sagner, 2014.

² Bragg, 2010; Polak, Robertson & Lind, 2011

Sul piano operativo, l'obiettivo di base consiste nel **garantire la liquidità necessaria** per far fronte alle uscite correnti, come: pagamenti commerciali, fisco, personale e rate dei finanziamenti. Quella che dall'esterno può sembrare una normale routine amministrativa, richiede invece un controllo continuo dei flussi di cassa, indispensabile per prevenire crisi di liquidità improvvise. Nella realtà operativa, la dinamica temporale dei flussi monetari è per sua stessa natura incerta. Ritardi negli incassi commerciali, urgenze dei fornitori o improvvise fluttuazioni sui mercati valutari generano continui *mismatch* tra la liquidità attesa e gli impegni reali. Di fronte a questa volatilità, il semplice presidio quotidiano non basta più: al cash manager serve un sistema previsionale solido, capace di intercettare le tensioni finanziarie prima che si manifestino e di abilitare manovre correttive tempestive.

Un ulteriore obiettivo, connesso con il primo, è quello di **contenere gli oneri finanziari**, il che rappresenta la prova più diretta della buona performance del cash management in termini di impatto sul conto economico aziendale. Una gestione previsionale solida, infatti, dà all'impresa un vantaggio temporale. Permette di anticipare i fabbisogni di cassa, scegliere i momenti ottimali per attingere a fonti di finanziamento e negoziare le condizioni in assenza di pressioni, molto prima che l'esigenza di liquidità diventi un'urgenza. Al contrario, un'impresa costretta ad attivare linee di credito in piena emergenza, quando il deficit di cassa si è già materializzato, perde di fatto la propria forza negoziale. In questi casi, si ritrova a finanziare il proprio fabbisogno a costi decisamente più elevati. Un esempio classico è quello di un'azienda manifatturiera con una marcata stagionalità negli incassi. Se il cash manager prevede la tensione finanziaria con tre-quattro settimane di anticipo, potrà negoziare l'apertura degli affidamenti a condizioni ottimali. Se invece l'esigenza emerge a pochi giorni dalle scadenze, l'impresa sarà costretta ad accettare passivamente i tassi offerti dalla banca in quel momento. L'impatto cumulato di questi extracosti, su base annua, incide in modo rilevante sui margini del conto economico³.

Il terzo obiettivo del cash management consiste nella **gestione efficiente del**

³ Sagner, 2014

WCR (*Working Capital Requirement*). Questa grandezza introduce una prospettiva di analisi più ampia, che va oltre la pura gestione di cassa per estendersi all'intera dinamica del ciclo operativo aziendale. Nello specifico, il WCR misura il fabbisogno finanziario netto dell'attività corrente, ovvero le risorse monetarie che l'impresa deve stabilmente immobilizzare per colmare il disallineamento temporale tra i propri impegni di pagamento e i futuri incassi commerciali. Ogni quota di capitale assorbita nel ciclo operativo sotto forma di crediti commerciali non ancora incassati, scorte di magazzino non ancora vendute o acconti versati ai fornitori rappresenta una risorsa sottratta all'investimento produttivo o alla remunerazione degli azionisti. La funzione di cash management agisce sulla velocità di incasso dei crediti, si basa sull'ottimizzazione dei termini di pagamento e punta alla riduzione dei livelli di scorta pur andando incontro alle esigenze operative. Questo approccio permette di liberare risorse significative e di migliorare in maniera netta la redditività del capitale investito⁴.

Per perseguire questi obiettivi, la funzione di cash management si articola in un insieme di macro-processi operativi tra loro complementari, che formano un ciclo continuo di pianificazione, esecuzione e controllo. Il processo più critico, e quello su cui l'innovazione tecnologica sta producendo gli effetti più profondi, è il ***cash forecasting***, ossia la previsione sistematica dei flussi di cassa attesi nel breve, medio e lungo periodo. La qualità di questa previsione costituisce la base informativa su cui si fondano tutte le successive decisioni di tesoreria; una previsione inaccurata, infatti, si propaga lungo l'intera catena delle decisioni finanziarie, deteriora pertanto i margini aziendali, dato che aumentano gli oneri e si riducono i rendimenti, ed innalza l'esposizione al rischio di illiquidità, generando un pericoloso squilibrio tra le immobilizzazioni e il capitale circolante.

All'attività predittiva del ***cash forecasting*** si affiancano processi volti a gestire materialmente la liquidità quotidiana, iniziando dalla ***cash concentration***. Quest'attività si realizza solitamente tramite il ***cash pooling***, ovvero una tecnica di tesoreria che permette di raggruppare le risorse sparse nei vari conti correnti

⁴ Polak et al., 2011

in un unico conto centrale. In questo modo è possibile compensare internamente i saldi negativi con quelli positivi, evitando di ricorrere a finanziamenti esterni e riducendo in maniera significativa gli interessi passivi da versare alle banche. Oltre all'accentramento, la tesoreria si occupa della gestione operativa degli incassi e dei pagamenti, lavorando per ottimizzare le tempistiche di regolamento e ridurre i giorni in cui il capitale rimane bloccato nelle transazioni. Infine, il ciclo si chiude con l'investimento della liquidità in eccesso. Quest'ultima operazione, spesso trascurata nei lunghi periodi storici di tassi a zero, ha riacquisito centralità dati i rapidi rialzi decisi dalla BCE e dalla Fed. Per capirne la portata, basti un semplice esempio: un'impresa con 5 milioni di euro di liquidità media in eccesso, se investisse tale somma a un tasso *overnight* (tasso d'interesse che dura esattamente un giorno lavorativo) del 3,5% anziché lasciarla infruttifera sul conto, genererebbe un rendimento aggiuntivo di circa 175.000 euro annui⁵. È evidente, dunque, come un *cash management* evoluto non sia un lusso riservato alle grandi multinazionali, bensì una vera e propria necessità strategica con un impatto diretto sulla competitività di ogni media impresa.

1.1.2 Le metriche di performance del cash management

La capacità di misurare con precisione la performance della funzione di cash management è essenziale per valutare il miglioramento nel tempo. Per l'appunto, un sistema di indicatori ben progettato compie tre funzioni distinte e complementari: consente al cash manager di orientare le proprie azioni operative verso obiettivi quantificabili; fornisce al CFO e al vertice aziendale una rappresentazione sintetica dell'efficienza con cui vengono gestite le risorse finanziarie correnti; infine, permette di dialogare con gli interlocutori bancari e con gli investitori in un linguaggio di benchmarking condiviso, che consente di rafforzare la credibilità dell'impresa come controparte affidabile.

Nella letteratura manageriale è possibile osservare lo sviluppo, nel tempo, di un insieme consolidato di metriche riconducibili a tre categorie analitiche principali: **indicatori operativi, indicatori finanziari e indicatori strategici.**

⁵ HSBC Global Banking, 2025

Ciascuna di queste categorie cattura una dimensione distinta della performance, e soltanto la loro lettura integrata consente una valutazione complessiva e non parziale della qualità della gestione della liquidità aziendale.

Gli indicatori operativi misurano l'efficienza con cui l'azienda gestisce quotidianamente i propri flussi monetari, concentrandosi in particolar modo sulle tempistiche di incasso, pagamento e movimentazione del magazzino. Tra questi, il **Cash Conversion Cycle (CCC)** rappresenta la metrica di sintesi per eccellenza, poiché riassume in un unico valore l'intero ciclo finanziario dell'impresa.

Nella sua formulazione classica, originariamente formalizzata da Lawrence J. Gitman (1974), il CCC esprime i giorni che intercorrono tra il pagamento ai fornitori per l'acquisto delle materie prime e l'effettivo incasso derivante dalla vendita del prodotto finito. Si calcola come somma algebrica di tre componenti: i giorni medi di incasso dei crediti commerciali (**DSO, Days Sales Outstanding**), i giorni medi di giacenza delle scorte (**DIO, Days Inventory Outstanding**), a cui si sottraggono i giorni medi di pagamento dei fornitori (**DPO, Days Payable Outstanding**):

$$\text{CCC} = \text{DSO} + \text{DIO} - \text{DPO}$$

Il significato economico di questa formula è molto intuitivo. Ipotizziamo che un'impresa impieghi in media 60 giorni per incassare dai clienti (DSO = 60), tenga la merce in magazzino per 30 giorni (DIO = 30) e paghi i fornitori a 45 giorni (DPO = 45). Il suo CCC sarà pari a 45 giorni (60 + 30 - 45). Questo risultato indica che l'impresa ha bisogno di finanziare, con risorse proprie o ricorrendo al debito bancario, ben 45 giorni di scoperto del proprio ciclo operativo. Per capire l'impatto reale di questa metrica, basti pensare che ridurre il CCC di soli 10 giorni per un'impresa da 200 milioni di fatturato (ipotizzando un costo del debito del 5%) permette di liberare circa 5,5 milioni di euro di capitale circolante, risparmiando oltre 270.000 euro di oneri finanziari all'anno. Proprio per questo impatto economico, il tesoriere lavora attivamente sulle tre leve manageriali che compongono il CCC. Il DSO può essere ridotto accorciando i termini di pagamento contrattuali, adottando politiche di recupero crediti più stringenti o ricorrendo al *factoring*. Il DPO, al contrario, segue una

logica inversa, ovvero quella di pagare i fornitori il più tardi possibile migliora la liquidità, ma è una leva da maneggiare con estrema cautela per non incrinare i rapporti commerciali o lanciare al mercato segnali di difficoltà finanziaria. Il DIO, infine, dipende dall'efficienza logistica e dalla capacità di prevedere accuratamente la domanda futura: un'impresa dotata di ottimi sistemi previsivi può permettersi di operare con scorte minime senza rischiare di rimanere senza merce. Non a caso, le analisi settoriali e le indagini settoriali sul capitale circolante condotte da The Hackett Group (2023) confermano che le aziende leader nel *cash management* presentano un CCC inferiore di oltre 10 giorni rispetto alla media dei diretti concorrenti, con vantaggi enormi in termini di redditività.

Se il CCC fotografa l'efficienza attuale, un secondo indicatore operativo tratta dell'accuratezza previsionale (*forecast accuracy*), la quale viene misurata tramite il **MAPE** (*Mean Absolute Percentage Error*), un indice che quantifica lo scostamento percentuale tra i flussi di cassa previsti e quelli che si sono effettivamente realizzati, secondo la formula:

$$\text{MAPE} = (1/n) \times \sum |\text{Actual} - \text{Forecast}| / \text{Actual} \times 100$$

Secondo dati della Global Digital Treasury Survey di PwC (2023), le aziende che effettuano le proprie proiezioni di cassa manualmente, tramite fogli di calcolo, registrano tipicamente un MAPE compreso tra il 15% e il 25%. Tradotto nella pratica, un margine d'errore di questa portata ha costi occulti elevatissimi. Si pensi a un'impresa che prevede flussi di cassa settimanali per 1 milione di euro: un errore del 20% significa dover gestire la tesoreria tollerando un'incertezza cronica di 200.000 euro. Per tutelarsi da queste sorprese, il tesoriere è costretto a mantenere un cuscino di liquidità extra di sicurezza (rinunciando quindi a investirlo per generare un rendimento) e a richiedere linee di credito precauzionali superiori al reale fabbisogno.

Infine, unitamente al MAPE, la prassi manageriale monitora il *forecast bias*, ovvero la tendenza strutturale a sovrastimare o sottostimare i flussi. Sovrastimare regolarmente le entrate genera un eccesso di liquidità immobilizzata che deprime il rendimento del capitale; sottostimarle, al contrario, espone pericolosamente l'impresa a improvvisi deficit di liquidità e ai conseguenti costi di emergenza

finanziaria.

Gli **indicatori finanziari** traducono l'efficienza operativa del *cash management* in grandezze economiche direttamente confrontabili con i parametri di valutazione aziendale, rendendo visibile al vertice dell'organizzazione, e agli interlocutori del mercato finanziario, il valore reale generato da una gestione accurata della liquidità.

Il primo parametro fondamentale è il **rapporto tra oneri finanziari netti e fatturato**, che costituisce un termometro sintetico del costo sostenuto dall'impresa per il ricorso al finanziamento esterno a breve termine. L'evoluzione nel tempo di questo indicatore rispecchia in modo sensibile la qualità del *cash management*. Un'impresa che migliora sistematicamente la propria *forecast accuracy* riesce a ridurre strutturalmente questo peso, poiché diventa in grado di attivare le linee di credito nelle finestre temporali di minor costo, evita scoperti di conto non pianificati e riduce drasticamente la dipendenza da forme di finanziamento d'emergenza, tipicamente molto più onerose⁶.

Un secondo indicatore cruciale è lo **spread applicato sulle linee di credito**, che sintetizza al contempo la qualità della relazione bancaria e la capacità dell'impresa di proiettare verso l'esterno segnali di solidità. La banca, nel determinare il *pricing* del credito a breve, non si limita infatti a valutare la solvibilità formale attraverso i tradizionali indici di bilancio, ma incorpora nel proprio giudizio valutazioni qualitative sulla *governance* finanziaria e sulla trasparenza della controparte. Le evidenze empiriche raccolte da Gartner (2023) su un campione di 200 aziende documentano come le imprese capaci di produrre previsioni di cassa sistematicamente accurate ottengano *spread* inferiori di 15-30 punti base rispetto a organizzazioni con processi meno sofisticati. Un'azienda che comunica con regolarità le proprie proiezioni e onora gli impegni nei tempi previsti costruisce progressivamente un vero e proprio asset reputazionale. Per un'impresa con 10 milioni di euro di fidi a breve termine, una riduzione di 20 punti base dello *spread* significa un risparmio di 20.000 euro annui, rendendolo un vantaggio competitivo tangibile e difficilmente replicabile nel breve termine da concorrenti meno strutturati.

⁶ Sagner, 2014

Infine troviamo il **Cash Idle Ratio**, calcolato come il rapporto tra le disponibilità liquide mantenute in forma infruttifera (o a rendimenti inferiori a quelli di mercato) e il fatturato annuo. Questa metrica misura il costo opportunità della liquidità non allocata in modo ottimale. Nel contesto post-2022, caratterizzato da tassi di riferimento della BCE saliti rapidamente dallo zero a livelli superiori al 4%, questo indicatore ha riacquisito una centralità assoluta. Mantenere fondi immobilizzati in conto corrente senza rendimento rappresenta oggi un'erosione di valore che i sistemi avanzati di *cash management* mirano a neutralizzare, garantendo un'allocazione dinamica e tempestiva delle eccedenze verso gli strumenti più redditizi del mercato monetario⁷.

Gli **indicatori strategici** valutano una dimensione dei risultati aziendali che va oltre la pura rilevazione contabile, fungendo da parametro per misurare la flessibilità e la resilienza di lungo periodo dell'impresa. In questo ambito, il primo presidio fondamentale per la continuità operativa è il rigoroso monitoraggio della liquidità rispetto ai **vincoli finanziari**. Si tratta di clausole vincolanti inserite nei contratti di finanziamento che obbligano l'azienda a mantenere precisi livelli minimi di cassa, specifici rapporti di copertura del debito (come, ad esempio, il DSCR - *Debt Service Coverage Ratio*) o determinati livelli massimi di indebitamento (spesso misurati attraverso un tetto al parametro PFN/EBITDA). La violazione di un vincolo finanziario può innescare clausole di esigibilità immediata del debito, autorizzando gli istituti di credito a richiedere il rimborso anticipato del prestito. Si tratta di un evento potenzialmente destabilizzante per l'intera struttura finanziaria, specialmente se si verifica in fasi di tensione sui mercati creditizi, quando le opzioni di rifinanziamento sono limitate e particolarmente onerose.

Per scongiurare simili scenari, non è sufficiente un'analisi retrospettiva dei saldi, è indispensabile dotarsi di un sistema di **early warning prospettico**. Questo indicatore valuta la capacità della tesoreria di segnalare l'avvicinamento a soglie critiche di liquidità con un adeguato anticipo (tipicamente da tre a cinque giorni lavorativi, ma idealmente da una a due settimane). Un preavviso tempestivo garantisce alla direzione aziendale lo spazio di manovra necessario per attuare

⁷ HSBC Global Banking, 2025

misure correttive d'emergenza: posticipare i pagamenti discrezionali, attivare linee di credito di riserva, cedere temporaneamente attività finanziarie a breve termine, oppure accelerare gli incassi concedendo sconti commerciali. Quest'ultima pratica, in particolare, viene oggi sempre più ottimizzata attraverso piattaforme digitali di *Dynamic Discounting*, le quali permettono una rinegoziazione automatica e in tempo reale dei termini di pagamento in cambio di uno sconto proporzionale ai giorni di anticipo. L'efficacia di questo sistema di *early warning* è direttamente proporzionale alla *forecast accuracy* sottostante, rendendo un'accurata previsione di cassa il vero e proprio scudo a tutela della sostenibilità finanziaria d'impresa.

Infine, un indicatore di assoluto rilievo per il vertice aziendale è il **time-to-decision sulle opportunità strategiche**. Esso misura il tempo di reazione della funzione finanziaria nel quantificare l'impatto di un'operazione straordinaria, come un'acquisizione societaria, un rilevante investimento in capitale fisso, una distribuzione straordinaria di dividendi o un riacquisto di azioni proprie (*buyback*), sulla liquidità e sul profilo di rischio. Un sistema di *cash management* evoluto, integrato con funzionalità di simulazione *what-if* in tempo reale, ovvero la capacità di condurre *stress test* e analisi di scenario per valutare preventivamente l'impatto di eventi avversi o straordinari, permette al Direttore Finanziario di abbattere questo *time-to-decision* da interi giorni a poche ore. Tali simulazioni culminano spesso nel calcolo del *Cash Flow at Risk* (CFaR), una metrica statistica avanzata che quantifica la massima potenziale carenza di liquidità a cui l'impresa potrebbe andare incontro in un dato orizzonte temporale. Questa reattività decisionale, unita a una misurazione così rigorosa del rischio estremo, si traduce in un formidabile vantaggio competitivo, mettendo l'azienda nelle condizioni di cogliere tempestivamente le opportunità di mercato senza rischiare di farsi paralizzare dalla lentezza delle analisi finanziarie interne.

1.1.3 Il valore strategico della liquidità aziendale

Il valore strategico della liquidità rappresenta un naturale punto di convergenza tra la finanza aziendale (*corporate finance*) e la strategia d'impresa. Negli ultimi decenni, la letteratura accademica ha dedicato un ampio filone di studi a questo

tema. Analizzarli oggi è fondamentale per comprendere le logiche di gestione della cassa in un contesto macroeconomico complesso, segnato da tassi di interesse volatili, catene di fornitura frammentate e forte incertezza geopolitica. L'analisi muove da una premessa solo all'apparenza controintuitiva: mantenere **liquidità in eccesso** (*excess cash*) rispetto ai normali fabbisogni operativi non costituisce necessariamente un'inefficienza, bensì una scelta razionale in grado di generare valore. Per inquadrare questo assunto occorre richiamare il celebre Teorema di Modigliani-Miller. In un mercato finanziario perfetto, privo di imposte, asimmetrie informative o costi di transazione, dove fonti interne ed esterne di finanziamento agiscono da perfetti sostituti, la politica di liquidità risulta del tutto irrilevante. In un simile scenario teorico, infatti, il credito bancario e la cassa interna avrebbero il medesimo costo; di conseguenza, immobilizzare capitali sul conto corrente, rinunciando a reinvestirli o a distribuirli agli azionisti, si tradurrebbe in una netta distruzione di ricchezza.

La realtà operativa, tuttavia, si discosta profondamente da tale perfezione. L'esistenza di asimmetrie informative, lo stato di tensione finanziaria (*financial distress*), i vincoli di accesso al credito e l'incertezza sui tassi rendono inapplicabile il modello neoclassico. Sono proprio queste "frizioni" di mercato a fondare la moderna teoria del **cash holding**, che attribuisce alle riserve di liquidità un valore strategico autonomo, essenziale per la competitività e la resilienza dell'impresa.

La formalizzazione più autorevole di questa prospettiva si deve allo studio di Opler, Pinkowitz, Stulz e Williamson (1999), tuttora considerato un imprescindibile punto di riferimento nella letteratura empirica. Attraverso l'analisi di un vasto campione di imprese statunitensi quotate, seguite nell'arco di un ventennio, gli autori dimostrano che il livello di liquidità trattenuta è positivamente correlato alla volatilità dei flussi di cassa operativi, alla presenza di vincoli nell'accesso al credito e all'intensità delle opportunità di crescita. Queste ultime vengono tipicamente approssimate dal *market-to-book ratio*, indicatore che riflette il premio riconosciuto dal mercato alle prospettive di sviluppo aziendale.

Tali evidenze corroborano il cosiddetto modello di *trade-off*. Secondo questo

paradigma, che declina in chiave aziendalistica il classico **movente precauzionale** di derivazione keynesiana, l'impresa determina la propria giacenza ottimale bilanciando due forze contrapposte. Da un lato agisce il costo opportunità della cassa in eccesso, dato dal differenziale tra il rendimento atteso dagli investimenti operativi e quello, tipicamente inferiore, offerto dagli impieghi sul mercato monetario. Dall'altro lato, emerge il beneficio assicurativo che la liquidità garantisce contro eventuali fasi di tensione finanziaria. Il mantenimento di adeguate riserve interne consente infatti alla direzione aziendale di finanziare progetti strategici anche in periodi di illiquidità generale, mitigando al contempo il rischio di dover ricorrere a prestiti d'emergenza a condizioni penalizzanti.

Tale impatto teorico, secondo cui la liquidità non costituisce un mero residuo passivo delle decisioni operative, bensì un *asset* strategico deliberatamente dimensionato in funzione del rischio e delle opportunità di crescita, ha trovato ulteriore e decisivo fondamento nello studio di Bates, Kahle e Stulz (2009). Gli autori documentano un fenomeno empirico apparentemente paradossale. Tra il 1980 e il 2006, le imprese statunitensi hanno progressivamente incrementato le proprie giacenze medie, passando da un'incidenza della liquidità sul totale attivo pari a circa il 10% a quasi il 24%. Tale accumulo si è verificato in netta controtendenza rispetto al contemporaneo sviluppo delle tecnologie di tesoreria e alla crescente sofisticazione dei mercati creditizi, fattori che avrebbero dovuto teoricamente contrarre il fabbisogno precauzionale. La spiegazione di questa dinamica risiede in tre fattori macroeconomici strutturali: l'aumento della volatilità dei flussi di cassa operativi, esacerbata dall'intensificarsi della concorrenza globale e dalla crescente variabilità della domanda; la crescente incidenza degli investimenti in beni immateriali (brevetti, marchi, capitale umano), i quali, a differenza degli *asset* fisici, presentano una limitata liquidabilità e una scarsa idoneità a fungere da garanzia (*collateral*) nei contratti di finanziamento bancario; infine, la progressiva riduzione del peso del magazzino sull'attivo, che ha di fatto eroso una storica riserva di liquidità secondaria a disposizione delle imprese nei momenti di tensione.

La rilevanza di questi contributi appare oggi ancora più marcata, in quanto capaci

di anticipare dinamiche strutturali che l'attuale contesto economico ha ulteriormente accentuato. L'estrema volatilità dei flussi di cassa, amplificata dalla fragilità delle catene di fornitura globali emersa con chiarezza durante la crisi del Covid-19; l'impennata dei tassi di interesse, che ha reso il ricorso al debito bancario a breve termine decisamente più oneroso rispetto al quinquennio precedente; la moltiplicazione dei rischi geopolitici, che ha ridotto la prevedibilità degli incassi esteri. Tutti questi elementi hanno accresciuto in modo strutturale il valore assicurativo della liquidità iscritta a bilancio. Parallelamente, tuttavia, la fine della prolungata era dei tassi a zero (*ZIRP - Zero Interest Rate Policy*) ha massimizzato il costo opportunità delle giacenze in eccesso. In questo complesso scenario, l'ottimizzazione del *cash holding*, attraverso l'individuazione di un rigoroso punto di ottimo che prevenga la vulnerabilità finanziaria dell'impresa senza deprimere la redditività del capitale investito, si configura come una priorità strategica per la direzione finanziaria. Un obiettivo raggiungibile esclusivamente attraverso solidi processi di previsione (*cash forecasting*) e un'allocazione dinamica ed efficiente delle risorse.

Proprio sul fronte dell'allocazione strategica delle risorse, un'ulteriore dimensione del valore della liquidità, di profondo impatto operativo, discende dall'applicazione del *framework* delle **opzioni reali** (*real options*) alla finanza d'impresa. L'assunto centrale, introdotto da Dixit e Pindyck (1994) e declinato a livello manageriale da Copeland e Antikarov (2001), è che la disponibilità di risorse liquide conferisca all'azienda la capacità di esercitare opzioni di crescita. Tali opzioni rappresentano il diritto, ma non l'obbligo, di cogliere opportunità di investimento discontinue, imprevedibili e spesso irripetibili, senza dover ricorrere in tempi brevi e a condizioni sfavorevoli al mercato del debito o dei capitali. In questa prospettiva, la liquidità cessa di essere un *asset* statico e difensivo per trasformarsi in un fondamentale abilitatore di flessibilità strategica. Un'impresa dotata di adeguate riserve interne può infatti reagire con tempestività per acquisire concorrenti in difficoltà, può sostenere i propri programmi di ricerca e sviluppo nelle fasi recessive (quando i *competitor* sono costretti a contrarli per preservare la cassa) e può resistere a improvvise restrizioni creditizie (*credit crunch*) senza dover liquidare attività strategiche a valori di

realizzo o rinunciare a investimenti redditizi. Il valore di questa opzionalità strategica cresce proporzionalmente alla volatilità dell'ambiente competitivo e all'imprevedibilità delle tempistiche (*timing*) di investimento, massimizzandosi in contesti di elevata incertezza sistemica come l'odierno scenario macroeconomico⁸.

Questo quadro analitico viene completato, nella sua valenza operativa, dalla prospettiva di *governance* introdotta da Pinkowitz, Stulz e Williamson (2016). Il loro studio dimostra come il **valore marginale** attribuito dal mercato alla liquidità iscritta in bilancio vari significativamente in funzione della qualità della *corporate governance* e del livello di protezione degli investitori. In sistemi istituzionali caratterizzati da una forte tutela degli azionisti di minoranza, tipici del modello anglosassone, un euro addizionale di cassa viene valutato dal mercato con un moltiplicatore prossimo o superiore all'unità, poiché gli investitori confidano in un'allocazione efficiente e allineata ai propri interessi. Viceversa, in contesti contraddistinti da una *governance* più debole, la liquidità subisce una valutazione a sconto rispetto al suo valore nominale. Il mercato, infatti, anticipa il rischio che tali risorse vengano distrutte attraverso investimenti a VAN (Valore Attuale Netto) negativo, intrapresi per assecondare logiche di espansionismo dimensionale del *management* (il noto fenomeno dell'*empire building*), oppure sottratte tramite operazioni opache a favore di soggetti interni, alimentando significativi costi di agenzia (*agency costs*). Tali evidenze empiriche delineano implicazioni cruciali per la funzione di *cash management*. La qualità dei processi allocativi, la trasparenza delle politiche d'investimento e il rigore nella comunicazione finanziaria superano il perimetro delle semplici *best practice* aziendali, configurandosi come leve strategiche in grado di incidere direttamente sul valore di mercato dell'impresa e sul suo costo del capitale.

Al fine di ricondurre la pluralità degli approcci fin qui esaminati, dai modelli empirici di *trade-off* fino alla teoria delle opzioni reali e della *corporate governance*, a un quadro sistematico unitario, risulta utile richiamare la classica tripartizione keynesiana⁹. Quest'ultima individua tre motivazioni fondamentali

⁸ Copeland & Antikarov, 2001

⁹ Keynes, 1936

alla detenzione di liquidità: il **movente transazionale** (le risorse necessarie ad assolvere le normali obbligazioni del ciclo operativo), il **movente precauzionale** (le riserve accantonate per fronteggiare shock esogeni e imprevisti) e il **movente speculativo** (la liquidità mantenuta prontamente disponibile per cogliere repentine opportunità di investimento, fungendo di fatto da presupposto operativo per l'esercizio di quelle *real options* discusse in precedenza).

Una funzione di *cash management* evoluta non si limita a presidiare la dimensione strettamente transazionale, per sua natura la più immediata e operativa, ma ottimizza in modo integrato il dimensionamento di tutte e tre le componenti. Un sistema previsivo accurato riduce le riserve precauzionali richieste per garantire un determinato grado di confidenza sulla solvibilità, liberando così capitali per impieghi produttivi; una visibilità in tempo reale sulla posizione netta aggregata consente di sfruttare tempestivamente le opportunità di natura speculativa; infine, l'automazione dei processi minimizza il rischio di errori operativi, i quali potrebbero generare improvvisi e inattesi fabbisogni transazionali. È proprio questa capacità di governare simultaneamente le tre dimensioni del *cash holding* a elevare l'investimento in tecnologie avanzate di tesoreria, con particolare riferimento alle soluzioni basate sull'Intelligenza Artificiale, oggetto centrale del presente lavoro, a leva strategica a pieno titolo, superando definitivamente la logica della mera razionalizzazione dei costi operativi¹⁰.

1.2 L'Evoluzione Storica del Cash Management: Da Funzione Operativa a Partner Strategico

La traiettoria evolutiva del *cash management* nel corso degli ultimi quattro decenni non può essere letta esclusivamente attraverso la lente del progresso tecnologico. Si tratta, al contrario, di un profondo cambiamento delle condizioni informative, cognitive e organizzative entro cui opera la funzione finanziaria d'impresa. Ogni fase di questa evoluzione ha corrisposto a una progressiva espansione del perimetro di visibilità del tesoriere sui flussi monetari aziendali

¹⁰ Opler et al., 1999; Bates et al., 2009

e, di conseguenza, a un ampliamento della sua capacità di incidere sulle decisioni strategiche. Ripercorrere questo percorso storico risulta essenziale per comprendere perché l'Intelligenza Artificiale non rappresenti una semplice estensione degli strumenti informatici già disponibili, bensì un vero e proprio salto di paradigma nella storia della disciplina.

1.2.1 L'era pre-digitale (1980-2000): Gestione manuale e processi cartacei

Nell'arco temporale compreso tra i primi anni Ottanta e la fine del secolo scorso, la funzione di *cash management* operava in un ecosistema aziendale caratterizzato da una marcata latenza informativa e da un'architettura dei dati fortemente frammentata in compartimenti stagni (*silos*). Le tecnologie dell'epoca, come: i fogli di calcolo elettronici nelle loro versioni più elementari, i sistemi di comunicazione interbancaria tramite telex o fax, e i *software* di contabilità di prima generazione; consentivano la sola registrazione storica dei saldi finanziari, ma non permettevano un'analisi dinamica né una proiezione sistematica dei fabbisogni futuri.

Il processo di elaborazione del *cash forecast* settimanale richiedeva la spunta manuale degli estratti conto bancari. Tale reportistica risultava disponibile, nella migliore delle ipotesi, con un giorno lavorativo di ritardo rispetto alla data valuta (T-1) e, di frequente, con differimenti ben più ampi dovuti ai fisiologici tempi tecnici di compensazione interbancaria (*clearing*). I flussi bancari venivano successivamente incrociati con lo scadenziario della contabilità clienti e fornitori. In assenza di architetture integrate, questo consolidamento avveniva interamente su supporti cartacei o sulle primissime versioni di applicativi, come Lotus 1-2-3 e, dalla seconda metà degli anni Ottanta, Microsoft Excel.

Conseguentemente, la stima dei flussi prospettici si fondava su approcci statistici rudimentali, quali: medie storiche mobili, analisi stagionali condotte tramite valutazioni empiriche e aggiustamenti discrezionali. In questo scenario pre-digitale, l'efficacia della funzione finanziaria non si misurava tanto sulla precisione algoritmica delle stime, quanto sulla capacità di governare le inefficienze temporali del sistema bancario. La priorità operativa era

l'ottimizzazione del cosiddetto **flottante** (*float*), definibile come l'arco temporale che intercorre tra l'esecuzione contabile di una transazione e la reale disponibilità liquida dei fondi sul conto corrente.

Sfruttare strategicamente lo squilibrio finanziario dei giorni di valuta tra le entrate e le uscite costituiva la vera competenza distintiva della tesoreria dell'epoca¹¹.

Tuttavia, in assenza di applicativi informatici in grado di calcolare e proiettare sistematicamente queste variabili complesse, la previsione della liquidità non poteva poggiare su basi scientifiche. È proprio per supplire a tale carenza tecnologica che subentrava il cosiddetto **giudizio esperto** (*expert judgment*). Nella letteratura statistica e previsionale, tale espressione designa un metodo di stima qualitativa fondato sulla conoscenza di dominio e sull'esperienza pregressa di uno specialista, tipicamente impiegato qualora i dati storici risultino destrutturati o i modelli matematici inapplicabili. Calato nella prassi della tesoreria pre-digitale, ciò significava che l'intuito personale del singolo *cash manager* non fungeva da mero correttivo umano a un modello quantitativo, bensì rappresentava l'unico, vero e proprio strumento a disposizione dell'impresa per stimare i fabbisogni di cassa futuri¹².

Tale dipendenza strutturale dal giudizio individuale esponeva la funzione finanziaria a pregiudizi ampiamente documentati dalla letteratura di finanza comportamentale. Kahneman e Tversky (1974), grazie al loro contributo sui processi decisionali in condizioni di incertezza, hanno dimostrato come i professionisti tendano sistematicamente a sovrastimare la propria capacità previsionale (*overconfidence bias*) e ad aggrapparsi alle informazioni più recenti (*recency bias*), a discapito di tendenze storiche. Questa dinamica psicologica si traduceva in un rischio aziendale tangibile: se un cliente storico aveva sempre pagato con puntualità, il tesoriere tendeva a dare per scontata la stessa regolarità anche per il futuro, finendo per ignorare i primi segnali di allarme sulle difficoltà finanziarie della controparte, pur in presenza di indizi anticipatori di deterioramento del suo credito. Si innescavano così inevitabili errori di stima, i

¹¹ Gallinger & Healey, 1991

¹² Armstrong, 2001

quali finivano per propagarsi a cascata lungo l'intera catena delle decisioni di *funding* aziendale, ovvero quell'insieme di scelte strategiche e operative volte a reperire risorse finanziarie necessarie per coprire i fabbisogni di cassa per garantire la continuità aziendale.

Ad aggravare l'impatto di queste distorsioni cognitive, interveniva la mancanza di chiarezza informativa all'interno dell'organizzazione. L'impossibilità di disporre di un quadro unitario e aggiornato della liquidità aziendale si rivelava un limite strutturale, avvertito in modo ancor più severo all'interno dei gruppi multi-divisionali o nelle imprese internazionalizzate. In contesti simili, il consolidamento dei saldi bancari richiedeva un oneroso processo manuale di estrazione e riconciliazione dei dati, in grado di assorbire la capacità lavorativa dell'intero *team* di tesoreria per diversi giorni alla settimana. L'*output* di tale processo amministrativo si traduceva in una fotografia della liquidità che, nel momento stesso della sua generazione, risultava però obsoleta. Come osservato da Sagner (2014), in questo regime informativo il tesoriere era costretto a operare non sulla consistenza effettiva delle disponibilità liquide, bensì su una loro approssimazione differita e potenzialmente viziata, sopportandone i rischi operativi e di liquidità.

Da una prospettiva strettamente economico-finanziaria, l'impatto di questo ritardo informativo si manifestava attraverso due principali canali. Il primo consisteva nel costante eccesso del **riserve di liquidità precauzionale**, ossia quella riserva strategica di mezzi liquidi accantonata dall'azienda per far fronte a uscite impreviste o shock finanziari. Non potendo stimare con precisione la traiettoria futura dei flussi, il tesoriere era indotto a mantenere riserve di cassa in eccesso rispetto al reale fabbisogno operativo. Questa scelta difensiva immobilizzava capitali che avrebbero potuto essere impiegati in investimenti produttivi o distribuiti agli azionisti. Il secondo canale di costo derivava dal ricorso improvviso a **forme di finanziamento a breve termine** a condizioni contrattuali nettamente più onerose rispetto a quelle negoziabili in assenza di urgenza. Considerando che, nel corso degli anni Ottanta, i tassi di interesse di riferimento in Europa e negli Stati Uniti oscillavano ordinariamente tra il 5% e il 15%, il costo opportunità generato da tali inefficienze erodeva in modo

tangibile i margini di redditività aziendale.

Di riflesso, il profilo di competenze richiesto al *cash manager* dell'epoca risultava coerente con la natura esecutiva della funzione. La professionalità del tesoriere si fondava sulla padronanza delle tecniche contabili, sulla conoscenza delle procedure operative, in particolare la gestione dei termini di valuta, le condizioni di sconto delle ricevute bancarie e l'utilizzo delle linee di credito autoliquidanti, e sulla capacità di instaurare relazioni di fiducia con i referenti degli istituti di credito.

La tesoreria operava in una logica puramente reattiva, la cui priorità assoluta consisteva nel mantenere l'equilibrio monetario di breve termine, ossia, garantire la puntualità dei pagamenti ed evitare gli scoperti di sconto, configurandosi di fatto come un'area aziendale separata dai processi di pianificazione d'impresa. I limiti tecnologici rendevano infatti impossibile l'elaborazione di simulazioni *what-if*, ossia la proiezione di scenari ipotetici volti a valutare preventivamente l'impatto di specifiche variabili sui futuri flussi di cassa. Di conseguenza, al dipartimento finanziario era preclusa la possibilità di supportare proattivamente il vertice aziendale nella valutazione degli impatti di liquidità legati a operazioni straordinarie, quali operazioni di M&A (Fusioni e Acquisizioni) o complesse ristrutturazioni del debito.

In questo scenario storico, la creazione di valore strategico attraverso una gestione attiva e predittiva della liquidità rimaneva un'eccezione. Essa era infatti appannaggio quasi esclusivo delle grandi imprese multinazionali, le quali risultavano le uniche a disporre delle risorse necessarie per dotarsi di strutture di tesoreria centralizzate e per accedere a costose tecnologie proprietarie di gestione dei flussi interbancari.

1.2.2 La digitalizzazione di base (2000-2015): ERP e Business Intelligence

L'inizio degli anni Duemila ha segnato una trasformazione profonda per la funzione di *cash management*, guidata dalla progressiva diffusione dei sistemi **ERP (Enterprise Resource Planning)**, mercato in cui *player* come SAP e Oracle assumevano posizioni di assoluta *leadership* e che avrebbero consolidato nei

decenni a venire, e dall'emergere delle prime soluzioni di **Business Intelligence (BI)** orientate specificamente alle esigenze della tesoreria aziendale.

Il contributo più dirompente di questi strumenti non è stato tecnologico in senso stretto, bensì architetturale e organizzativo. Tali sistemi hanno infatti permesso di superare la storica frammentazione tra le aree aziendali, automatizzando la raccolta dei flussi informativi provenienti dai diversi cicli gestionali, sia attivo che passivo. Per la prima volta, infatti, i dati finanziari rilevanti per la gestione della liquidità venivano raccolti, strutturati e resi accessibili all'interno di un unico ecosistema integrato, garantendo una visibilità sui saldi e sui flussi vicina al tempo reale. Questo cambio di paradigma ha posto le basi per una drastica riduzione delle asimmetrie informative interne, trasformando il dato da frammento isolato a patrimonio informativo condiviso.

Più nel dettaglio, gli **ERP (Enterprise Resource Planning)** si configurano come software modulari progettati per gestire in modo integrato tutte le attività *core* di un'impresa, dalla contabilità alla logistica, dalle vendite alle risorse umane, attraverso un'unica base dati centralizzata. La centralità di questi sistemi nella trasformazione del *cash management* risiede nella loro capacità di ricomporre la frammentazione dei dati che aveva caratterizzato la gestione finanziaria del passato. Nell'architettura che vi era prima degli ERP, le informazioni necessarie per prevedere i flussi di cassa erano disperse in database isolati e non comunicanti: la contabilità clienti (ciclo attivo), quella fornitori (ciclo passivo) e persino i dati di magazzino risiedevano su applicativi differenti.

L'integrazione di queste fonti in un ambiente unico, come hanno fatto i sistemi SAP o Oracle, ha consentito, per la prima volta, di interrogare simultaneamente la posizione dei crediti, il piano dei pagamenti e le giacenze fisiche, producendo una visione della liquidità aziendale coerente e tempestiva¹³.

Sul piano operativo, l'adozione dell'ERP ha trasformato la **riconciliazione bancaria**, automatizzando l'attività di riscontro tra i flussi finanziari esterni e le scritture contabili interne. Quello che nell'era precedente richiedeva giorni di confronto manuale tra estratti conto cartacei e registrazioni contabili, è divenuto un processo semi-automatico; gli ERP hanno infatti rivoluzionato tale attività

¹³ Polak et al., 2011

centralizzando in un unico ambiente sia il ciclo attivo e passivo (le fatture caricate a sistema), ed anche i flussi telematici provenienti dalle banche. L'adozione di standard internazionali per lo scambio di dati finanziari, come il file **SWIFT MT940** (lo standard globale per la trasmissione telematica degli estratti conto interbancari) che ha permesso agli ERP di abbinare automaticamente le transazioni bancarie con gli ordini di pagamento e le previsioni di incasso registrate a sistema.

Con le prime versioni dei moduli di tesoreria, il tasso di riconciliazione automatica si attestava mediamente intorno al 70-75% delle transazioni totali. Questo risultato ha permesso di liberare la funzione di tesoreria dalle attività ripetitive di *data-entry*, consentendo agli addetti di focalizzarsi esclusivamente sulla risoluzione delle eccezioni, quali i pagamenti parziali o le ricevute con codici di riferimento errati.

Sebbene tale efficienza rappresentasse già un miglioramento, la successiva introduzione di algoritmi di *machine learning* avrebbe permesso di spingere questa soglia oltre il 90%, riducendo drasticamente la necessità di intervento umano¹⁴.

Se l'automazione della riconciliazione ha risolto le criticità legate alla gestione dei dati storici, l'impatto degli ERP sul *cash forecasting* (previsione dei flussi di cassa) è stato più graduale e, per certi versi, ambivalente.

Da una parte, la disponibilità di dati strutturati e consistenti ha permesso di applicare metodologie statistiche sofisticate, precedentemente inutilizzabili sui comuni fogli di calcolo. È il caso dei **modelli ARIMA (AutoRegressive Integrated Moving Average)**, algoritmi in grado di analizzare le serie storiche per identificarne *trend* e stagionalità; grazie all'integrazione in moduli software dedicati, tali strumenti sono diventati accessibili anche a *team* di tesoreria non specializzati. L'adozione di questi modelli ha permesso di migliorare la precisione delle stime, riducendo sensibilmente lo scarto tra la liquidità prevista e quella effettivamente realizzata. Tale scarto viene misurato attraverso il **MAPE (Mean Absolute Percentage Error)**, un indicatore che esprime la percentuale media di errore delle previsioni: grazie agli algoritmi statistici, le aziende sono

¹⁴ Citigroup, 2025

passate da un errore del 18-25% (tipico dei calcoli manuali basati su semplici medie storiche) a una soglia molto più contenuta, tra il 12% e il 16%¹⁵. Per un tesoriere, questo significa avere una visione molto più affidabile delle disponibilità future, riducendo la necessità di mantenere eccessive riserve di liquidità precauzionale.

Tale progresso, sebbene rilevante, ha però fatto emergere un limite strutturale per la digitalizzazione di base, ossia la **qualità del dato**. Il noto principio informatico del “*garbage in, garbage out*” ha trovato un’applicazione immediata nella tesoreria, secondo cui l'affidabilità dell'output di qualsiasi sistema dipende strettamente dalla qualità dei dati in ingresso. Gartner (2023) evidenzia come ancora oggi il 68% delle aziende identifichi la scarsa "pulizia" dei dati come il principale costo imprevisto e il maggiore freno ai progetti di trasformazione digitale basati sull'Intelligenza Artificiale.

Proprio per superare i limiti analitici degli ERP e valorizzare il patrimonio informativo raccolto per il potenziamento della funzione di cash management, la seconda metà del primo decennio del millennio ha visto l'affermazione delle soluzioni di **Business Intelligence (BI)**. In ambito finanziario, la BI si definisce come l'integrazione di modelli e tecnologie volti a trasformare i dati grezzi in informazioni fondamentali per guidare le scelte strategiche della tesoreria. Le piattaforme di settore hanno abilitato la creazione di dashboard interattive per il monitoraggio in tempo reale delle posizioni di cassa. Tali sistemi hanno introdotto la possibilità di condurre analisi multidimensionali (per valuta, *business unit* o area geografica) e di implementare simulazioni **what-if**, fondamentali per valutare l'impatto di scenari ipotetici sulla liquidità di gruppo. L'integrazione della BI ha segnato il passaggio da una rendicontazione di natura meramente consuntiva a una prospettiva di tipo predittivo, dove lo studio degli andamenti storici diventa un supporto fondamentale per le scelte di pianificazione finanziaria.

Parallelamente a questa evoluzione analitica, si è consolidato il modello della **tesoreria centralizzata**, reso operativo dalla diffusione delle strutture di **cash pooling**. Questo meccanismo di gestione della liquidità si è articolato

¹⁵ Hyndman e Athanasopoulos, 2021

principalmente in due varianti: il **Notional Pooling (compensazione per saldi)**, ovvero, una forma di compensazione basata sulla somma algebrica dei saldi dei singoli conti; questo permette di ottimizzare il calcolo degli interessi e ridurre gli oneri fiscali senza la necessità di trasferire fisicamente i fondi tra le diverse società del gruppo, e lo **Zero Balancing (ZBA – Compensazione per movimentazione)**, caratterizzato dal trasferimento fisico e automatico di ogni eccedenza dai conti periferici verso il conto accentrate (*header account*), portando a zero il saldo dei conti secondari al termine della giornata operativa. Questa architettura, supportata dai protocolli di messaggistica **SWIFT**, ossia, lo standard globale per lo scambio sicuro di dati finanziari, e dal sistema di regolamento **TARGET2** (il sistema di regolamento lordo in tempo reale dell'Eurosistema), ha garantito la gestione della liquidità *intraday*, riducendo drasticamente la necessità di ricorrere a forme di finanziamento esterno a breve termine.

Un esempio concreto di questa trasformazione è offerto dal percorso di **Siemens**, multinazionale che ha rappresentato un caso di studio per l'intero settore della tesoreria¹⁶. L'azienda è passata da una struttura finanziaria altamente frammentata, caratterizzata da centinaia di conti locali difficili da monitorare, a un modello di gestione globale integrata. Grazie all'implementazione di sistemi proprietari avanzati, il gruppo è riuscito a convogliare l'88% dei propri saldi mondiali in un'unica infrastruttura centrale. Questo ha permesso al corporate di ottenere il controllo diretto sulla quasi totalità della liquidità distribuita nelle sue filiali globali, eliminando i ritardi informativi e i costi di gestione che caratterizzavano l'era precedente.

Il consolidamento degli ERP e delle soluzioni di Business Intelligence è stato accompagnato, nel medesimo arco temporale, dalle prime applicazioni della **Robotic Process Automation (RPA)** ai processi di tesoreria. Questa tecnologia non si è posta come un'alternativa ai sistemi esistenti, ma come uno strumento di integrazione volto ad automatizzare quelle attività manuali e ripetitive che rimanevano scoperte dai grandi software gestionali.

A differenza dell'intelligenza artificiale, la RPA non apprende dai dati, ma

¹⁶ Siemens AG/Deutsche Bank, 2025

esegue in modo automatico e ripetitivo sequenze predefinite di operazioni, simulando l'interazione di un operatore con le interfacce dei sistemi informatici. Nel contesto del *cash management*, le applicazioni più diffuse hanno riguardato l'automazione del *data entry* per il caricamento degli estratti conto bancari, il *matching* automatico delle fatture con gli ordini di pagamento e la generazione automatica dei *report* di tesoreria.

L'impatto in termini di riduzione dei tempi operativi è stato significativo ma i limiti strutturali della RPA sono diventati progressivamente evidenti. Il suo funzionamento, infatti, è strettamente vincolato a tre fattori di rigidità: dalla **stabilità delle interfacce**, poiché anche un minimo aggiornamento grafico dei sistemi sottostanti può bloccare il processo; non tollera alcuna **variazione nei formati dei dati di input**, richiedendo che ogni informazione sia presentata in modo identico e standardizzato; infine, il sistema non è in grado di **adattarsi autonomamente a situazioni impreviste**, restando confinato esclusivamente entro il perimetro delle regole di automazione predefinite.

Nonostante i significativi traguardi raggiunti, questa fase di digitalizzazione ha ereditato dei limiti strutturali che avrebbero poi dettato le priorità su cui intervenire del decennio successivo. Tali criticità si manifestavano innanzitutto in una persistente **ritardo nella disponibilità dei dati bancari**. Nonostante l'evoluzione degli ERP, la visibilità sulla cassa in tempo reale era limitata. Il consolidamento dei saldi provenienti da banche e valute differenti richiedeva infatti tempi di elaborazione lunghi, rendendo i dati disponibili con alcune ore di ritardo rispetto all'effettiva movimentazione dei fondi. A questa barriera temporale si affiancava la **difficoltà di scalare i modelli previsionali**, la cui gestione diventava sempre più complessa al crescere dell'organizzazione.

Infatti, l'applicazione di modelli ARIMA richiedeva appunto una configurazione manuale specifica per ogni singola società controllata. Per una multinazionale con decine di consociate, questo si traduceva in un carico di lavoro insostenibile per i team di tesoreria. Di conseguenza, risultava impossibile ottenere una visione previsionale completa e analitica, costringendo i tesorerieri a concentrare gli sforzi solo sulle sedi principali.

A questi limiti si aggiunge inoltre l'**isolamento dei dati interni all'impresa**, i

quali restavano privi di una reale integrazione con le variabili esogene. La mancata correlazione con indicatori macroeconomici, condizioni di mercato e modelli di pagamento dei clienti impediva di affinare la precisione delle previsioni oltre i livelli consentiti dalla sola analisi dei dati storici interni. L'insieme di questi vincoli ha tracciato il perimetro d'azione della fase successiva, definendo le sfide che l'intelligenza artificiale sarebbe stata chiamata a risolvere.

1.2.3 La rivoluzione AI (2015-oggi): Cash management intelligente e predittivo

A partire dalla metà del secondo decennio del millennio, una convergenza di fattori tecnologici ha determinato un cambiamento di paradigma nel *cash management* che va ben oltre la semplice evoluzione degli strumenti disponibili. Il motore principale di questo cambiamento è stato la maturazione del **Machine Learning**, inteso come l'insieme di algoritmi che permettono ai sistemi di identificare schemi logici nei dati e migliorare le proprie prestazioni in modo autonomo. In particolare, si sono distinti i modelli **Deep Learning** (un'architettura basata su reti neurali stratificate capaci di estrarre autonomamente caratteristiche complesse dai dati) e le reti **Long Short-Term Memory (LSTM)**, progettate per gestire sequenze temporali preservando la memoria di lungo periodo delle informazioni rilevanti. L'efficacia di queste ultime nella previsione delle serie finanziarie è stata documentata da Siami-Namini, Tavakoli e Namin (2019).

L'affermazione di queste architetture ha coinciso con tre fenomeni decisivi: la diffusione del **cloud computing**, ovvero la fornitura di servizi di calcolo e stoccaggio dati via internet, che ha eliminato la necessità di costose infrastrutture hardware locali rendendo l'IA accessibile anche a realtà di medie dimensioni; l'apertura dei sistemi bancari tramite le **API (Application Programming Interface) di Open Banking**, si tratta di interfacce standardizzate che consentono lo scambio sicuro e immediato di dati finanziari tra istituti bancari e terze parti, istituzionalizzate nell'UE dalla direttiva PSD2 del 2018; e, infine, la **disponibilità di grandi volumi di dati**, sufficientemente ampi da consentire l'addestramento di modelli predittivi ad alta accuratezza. La combinazione di tali

spinte tecnologiche non ha rappresentato un semplice perfezionamento tecnico, ma una vera e propria trasformazione qualitativa della funzione tesoreria.

Il contributo fondamentale del Machine Learning al *cash forecasting* risiede nella capacità di apprendere autonomamente modelli complessi e non lineari direttamente dai dati, superando i limiti strutturali dei modelli statistici classici. In termini operativi, un modello LSTM basato su uno storico di tre-cinque anni è in grado di identificare e correlare automaticamente stagionalità sovrapposte che sfuggono alla logica dei modelli classici.

Come documentano Aldasoro e Desai (2025) nel loro *Working Paper* per la Bank of Canada, la struttura algoritmica è in grado di assimilare questa molteplicità informativa in modo automatico, riproporzionando il peso delle diverse fonti in funzione del loro reale potere predittivo osservato nel tempo. Questa specifica capacità, definita **continuous learning** (apprendimento continuo), permette al modello di addestrarsi periodicamente sui dati più recenti senza richiedere alcun intervento umano, segnando una rottura netta con il paradigma statico dei modelli ARIMA, i cui parametri esigevano costanti e laboriose revisioni manuali per adattarsi ai mutamenti strutturali del mercato.

Parallelamente all'evoluzione quantitativa dei modelli predittivi, a partire dal 2020 l'emergere dell'**Intelligenza Artificiale Generativa** e dei **sistemi agentici**, ovvero modelli avanzati in grado non solo di elaborare informazioni, ma di pianificare ed eseguire azioni in autonomia ha aperto un capitolo inedito per la pratica manageriale. L'introduzione dei **Large Language Model (LLM)**, a famiglia di architetture neurali alla base di sistemi come ChatGPT, Gemini, Claude e affini, ha dotato la tesoreria aziendale di interfacce conversazionali avanzate. Questo salto tecnologico è cruciale poiché rende i complessi modelli matematici di previsione accessibili non solo a tecnici e *data scientist*, ma direttamente al management: oggi il CFO o il *cash manager* possono interrogare i sistemi sulle posizioni di liquidità formulando le proprie richieste in formato testuale libero o attraverso comandi discorsivi intuitivi.

Spingendosi oltre la semplice conversazione, questi modelli stanno evolvendo in veri e propri **assistenti digitali proattivi**. Come illustrato da PYMNTS (2025) e dimostrato empiricamente da Aldasoro e Desai (2025), gli agenti autonomi

basati su LLM sono già in grado di segnalare anomalie, suggerire azioni correttive repentine (come la variazione delle coperture valutarie o l'attivazione di linee di credito) e persino gestire attivamente la liquidità *intraday* nei complessi sistemi *wholesale* (ossia, circuiti interbancari per i pagamenti di importo rilevante), riducendo i ritardi nei pagamenti.

Il fondamento tecnologico che rende possibile tale livello di automazione è il *framework* dell'**Intelligenza Artificiale agentica**. In questo paradigma, il sistema non si limita a un'analisi passiva, ma percepisce costantemente lo stato dell'ambiente finanziario (la posizione di cassa, i flussi attesi, la volatilità dei mercati), elabora una strategia di ottimizzazione e, laddove autorizzato, esegue materialmente le transazioni. Come evidenziato dalle analisi di Treasury Intelligence Solutions (2025), le piattaforme di tesoreria stanno transitando verso veri e propri **sistemi di esecuzione attiva**, capaci di disporre in autonomia trasferimenti intragruppo, ripianamenti di conto e investimenti in strumenti del mercato monetario. Tuttavia, il passaggio all'autonomia totale incontra un limite della supervisione umana integrata, nota come paradigma dello *human-in-the-loop*. La necessità di mantenere un operatore umano per l'approvazione finale delle decisioni che superano specifiche soglie di importo o di rischio rimane un requisito imprescindibile, imposto sia dalle *policy* di *governance* interna, sia dalle crescenti aspettative dei regolatori sull'uso dell'IA in ambito finanziario.

L'adozione di questi sistemi di esecuzione attiva genera ricadute profonde sul disegno organizzativo della funzione finanziaria, modificandone radicalmente la struttura e le competenze richieste. L'impatto più evidente riguarda la riallocazione del tempo lavorativo: secondo un'analisi condotta da Deloitte (2024) su un campione di responsabili finanziari, nelle organizzazioni che hanno integrato soluzioni di intelligenza artificiale, l'incidenza delle mansioni puramente operative, come la raccolta dati, le riconciliazioni e la reportistica di routine, si è ridotta drasticamente, passando dal 60-70% tipico dell'era pre-digitale a un marginale 20-30%.

Il tempo liberato dall'automazione viene riassorbito in attività a maggior valore aggiunto, come l'analisi strategica degli scenari, consulenza al vertice aziendale e gestione proattiva delle relazioni bancarie. Questa dinamica trova conferma nel

percorso evolutivo di **Siemens**¹⁷. L'implementazione di architetture basate su intelligenza artificiale ha infatti liberato il team di tesoreria dalle attività transazionali di base, trasformando gli operatori in generalisti versatili. Tale transizione dimensionale sancisce la definitiva evoluzione del *cash management* da tradizionale centro di costo a vero e proprio **centro di creazione di valore** per l'impresa.

Tuttavia, l'assunzione di un ruolo aziendale così strategico e tecnologicamente avanzato introduce un ulteriore livello di complessità che l'analisi manageriale non può trascurare, ossia la dimensione regolamentare e la gestione del rischio algoritmico. L'entrata in vigore **dell'AI Act dell'Unione Europea nel 2024** ha segnato uno spartiacque normativo, classificando i sistemi di intelligenza artificiale impiegati per la valutazione del rischio di credito e la gestione dei servizi finanziari tra le applicazioni ad alto rischio. Questa classificazione impone stringenti **obblighi di governance, trasparenza e accountability**, traducendosi in requisiti pratici come la tenuta di una documentazione tecnica dettagliata, la tracciabilità delle decisioni automatizzate (*audit trail*) e la garanzia di una supervisione umana sugli output più critici.

Le preoccupazioni del legislatore europeo trovano eco nelle direttive del **Financial Stability Board e della Bank for International Settlements (2023)**, le quali ribadiscono l'urgenza di integrare i controlli sull'IA all'interno dei preesistenti *framework* di gestione del rischio operativo. Al centro delle preoccupazioni normative vi è il cosiddetto problema della **black box (scatola nera)**, che descrive l'impossibilità di tracciare il funzionamento interno di un algoritmo. Infatti, i modelli di apprendimento più complessi, pur fornendo previsioni estremamente accurate, si comportano come sistemi chiusi, restituendo un risultato finale senza esplicitare i passaggi intermedi e il percorso logico utilizzati per calcolarlo. In ambito finanziario, dove ogni decisione deve poter essere giustificata ai regolatori, questa mancanza di trasparenza rappresenta un grave rischio di conformità e reputazionale. Per risolvere questa criticità, le aziende stanno affiancando ai modelli previsionali strumenti di **Explainable AI (XAI)**, ovvero sistemi progettati per rendere interpretabili le

¹⁷ AG/Deutsche Bank, 2025

decisioni dell' algoritmo. Tra questi spiccano i valori SHAP (*SHapley Additive exPlanations*), strumenti matematici avanzati che permettono di "decomporre" la previsione finale del modello, quantificando il peso e il contributo di ogni singola variabile di *input* e rendendo così interpretabili anche le architetture neurali più complesse.

Il quadro normativo globale, tuttavia, è tutt'altro che consolidato. Come evidenziato in un recente *report* del **Dipartimento del Tesoro degli Stati Uniti (2024)**, la velocità di adozione di queste tecnologie ha ampiamente superato la capacità di adattamento delle leggi, rendendo necessaria una più stretta cooperazione internazionale. Questo *gap* regolamentare agisce come un'arma a doppio taglio. Da un lato espone il sistema a potenziali usi impropri o effetti a catena imprevisti; dall'altro, offre una straordinaria opportunità strategica. Le imprese che scelgono di implementare proattivamente standard di *governance* interna più severi di quelli attualmente richiesti dalla legge, trasformano la *compliance* in un vero e proprio asset reputazionale, consolidando la fiducia presso i propri interlocutori istituzionali e partner bancari.

Questa capacità di governare proattivamente l'innovazione tecnologica e normativa rappresenta il punto di arrivo di un lungo percorso di maturazione strutturale. Ripercorrendo le tappe fin qui analizzate, emerge come l'era pre-digitale avesse inizialmente circoscritto il problema, la gestione della liquidità esigeva informazioni precise e tempestive che i processi manuali non erano in grado di fornire. La successiva fase di digitalizzazione ha parzialmente colmato questo vuoto, riducendo le asimmetrie informative interne tramite l'adozione dei sistemi ERP e abilitando i primi rudimentali approcci statistici. L'odierna integrazione dell'Intelligenza Artificiale è infine intervenuta per abbattere i vincoli strutturali ancora irrisolti, portando la funzione di tesoreria verso un regime di operatività continua e di esecuzione autonoma.

1.3 L'Intelligenza Artificiale nel Cash Management: Tassonomia Applicativa

Dopo aver ripercorso l'evoluzione storica che ha condotto la tesoreria verso l'era predittiva, l'analisi abbandona l'asse cronologico per sistematizzare gli ambiti concreti in cui l'Intelligenza Artificiale genera oggi valore per l'impresa.

A questo scopo, il presente paragrafo introduce una tassonomia applicativa, nella quale vengono strutturati gli algoritmi in base alle specifiche sfide finanziarie che sono chiamati a risolvere: dalla gestione dei pagamenti, all'ottimizzazione della liquidità, fino al presidio delle frodi. Partire dalle esigenze operative permette di spiegare il funzionamento degli algoritmi in base ai problemi reali che risolvono, ponendo le basi per l'analisi dei costi e benefici sviluppata successivamente nel secondo capitolo.

1.3.1 Fondamenti di AI e Machine Learning per manager

L'integrazione dell'intelligenza artificiale nella tesoreria non è un semplice avanzamento tecnologico, ma un'evoluzione che impone al CFO e al Treasurer l'acquisizione di nuove strategie. Assimilare i paradigmi dell'apprendimento automatico, dalla loro logica economica alle implicazioni operative, è oggi un requisito indispensabile per gestire processi critici come la selezione di piattaforme di *cash forecasting* o la negoziazione di *contratti SaaS (Software as a Service)*. In questo modello di distribuzione, ormai standard nel settore, l'applicativo non viene installato localmente ma risiede nel *cloud* del fornitore specializzato, venendo erogato come servizio su abbonamento; una configurazione che sposta il focus manageriale dalla manutenzione tecnica del software alla qualità e alla sicurezza del flusso di dati gestito dal *vendor*.

In quest'ottica, il presente paragrafo delinea una tassonomia applicativa dell'AI finalizzata ad ottimizzare i complessi processi di gestione della liquidità, del rischio e dell'efficienza. Il pilastro di questa analisi è la distinzione tra i tre modelli che strutturano il *machine learning*: **supervised**, **unsupervised** e **reinforcement learning**. Questi approcci non sono semplici categorie tecniche, ma rappresentano logiche decisionali distinte. La scelta dell'uno o dell'altro dipende dalla natura del problema finanziario da risolvere e dalla tipologia di

valore che si intende generare per l'impresa.

Il modello del **Supervised Learning** (Apprendimento Supervisionato), costituisce il fondamento operativo delle applicazioni AI oggi più diffuse in tesoreria. Il suo funzionamento si basa sulla capacità dell'algorithmo di identificare i legami statistici tra un set di variabili di partenza (input) e il risultato finale già registrato dall'azienda (output). Durante lo sviluppo del modello, il sistema analizza vaste serie storiche in cui ogni insieme di input è associato al relativo risultato, come l'effettivo flusso di cassa generato in una specifica settimana o l'esatto ammontare incassato da una controparte. In questo modo, il modello apprende a correlare i dati aziendali con gli obiettivi finanziari prefissati. Una volta validato, il sistema acquisisce capacità predittiva: esso non si limita a replicare i dati passati, ma è in grado di elaborare previsioni attendibili su scenari nuovi, avendo interiorizzato le logiche ricorrenti che governano i flussi finanziari dell'impresa.

Oltre alla sua naturale applicazione nel *cash forecasting*, un'ulteriore direttrice strategica per incrementare la profittabilità della funzione finanziaria risiede nella **schedulazione intelligente dei pagamenti in uscita**. La gestione dei termini di pagamento ai fornitori è, tradizionalmente, un delicato equilibrio manuale tra l'impegno di onorare le scadenze contrattuali, la necessità di preservare liquidità disponibile e l'opportunità di catturare gli sconti per pagamento anticipato (*early payment discounts*). Un fornitore che offre condizioni "2/10 net 30" (sconto del 2% per pagamento entro 10 giorni rispetto a una scadenza ordinaria a 30 giorni) sta implicitamente offrendo un rendimento annualizzato prossimo al 36% sul capitale anticipato. Si tratta di una forma di finanziamento commerciale estremamente onerosa per chi vi rinuncia; eppure, l'evidenza empirica prodotta da Seifert e Seifert (2011) evidenzia come la maggior parte delle organizzazioni non riesca a cogliere tali opportunità a causa di una insufficiente visibilità sulla posizione netta di liquidità *intraday* o della complessità insita nel coordinare manualmente i flussi di cassa con le scadenze del passivo.

È qui che il *supervised learning* manifesta la propria capacità trasformativa. Infatti, un modello basato su dati storici che integra previsioni di *cash flow* a

breve termine, saldi disponibili per banca e covenant finanziari è in grado di calcolare, in modo continuo e automatizzato, la finestra ottimale di esecuzione di ciascun pagamento. Il sistema non si limita a segnalare lo sconto disponibile, ma valuta se la liquidità prevista nei primi dieci giorni consente di anticipare il pagamento senza esporre l'azienda a rischi di scoperti bancari (*overdraft*). L'implementazione di soluzioni AI per l'ottimizzazione dinamica dei pagamenti, mostra una capacità di catturare opportunità di sconto commerciale nell'ordine del 5-10% in più rispetto alle pratiche manuali, avendo contestualmente una riduzione degli episodi di tensione finanziaria inattesa. La dimensione economica di questo beneficio può essere considerevole. Per un gruppo industriale con un volume di acquisti annuo di 500 milioni di euro, qualora l'impresa riuscisse, grazie alla precisione dell' algoritmo, a catturare uno sconto medio del 2% su una quota di pagamenti precedentemente non gestita in modo ottimale, il risultato si tradurrebbe in risparmi netti per diversi milioni di euro l'anno. In quest'ottica, la transizione da una gestione reattiva a una pianificazione guidata dall'algoritmo non rappresenta solo un miglioramento operativo, ma un diretto contributo alla redditività dell'impresa.

L'efficacia dei modelli di previsione e ottimizzazione fin qui descritti incontra un limite strutturale per la quale, la loro capacità d'azione è delimitata dalla disponibilità di serie storiche che contengano già le informazioni necessarie a mappare il futuro. Questo approccio basato sul passato si rivela tuttavia insufficiente quando l'esigenza della tesoreria non è più quella di prevedere flussi ordinari, ma quella di intercettare anomalie o irregolarità mai verificate in precedenza. Poiché tali eventi non sono presenti nei database storici, occorre un sistema capace di segnalare qualsiasi operazione che si discosti dalla consuetudine aziendale. A questa esigenza risponde un altro modello, ovvero, **l'Unsupervised Learning** (Apprendimento non Supervisionato).

La discontinuità rispetto al modello precedente è profonda. In questo paradigma, non esiste una risposta corretta prestabilita a cui tendere; l'algoritmo esamina in totale autonomia l'insieme dei flussi informativi alla ricerca di correlazioni inattese o di deviazioni significative rispetto all'**operatività ordinaria dell'impresa**. Tradotto in termini gestionali, l'apprendimento non

supervisionato agisce come un meccanismo di monitoraggio ispettivo evoluto: esso non si limita a classificare casistiche già note, ma ricostruisce dal basso la struttura latente dei dati, facendo affiorare in modo naturale qualsiasi elemento di incoerenza.

Nel contesto della tesoreria, l'applicazione più critica di questo paradigma risiede nella **Fraud Detection** (rilevamento delle frodi) e nell'identificazione di irregolarità nei pagamenti in uscita. L'impatto economico di tale fenomeno è considerevole. Secondo il report dell'Association of Certified Fraud Examiners¹⁸, le frodi interne erodono in mediana il 5% del fatturato annuo delle organizzazioni, con tempi di latenza nella scoperta che oltrepassano di frequente i dodici mesi. La debolezza dei sistemi di controllo tradizionali, fondati su *policy* statiche, limiti di importo o riconciliazioni periodiche, consiste nella loro natura strutturalmente reattiva: operando *ex post*, si limitano a rilevare l'illecito quando la sottrazione di risorse si è già compiuta. Inoltre, un sistema basato su regole rigide risulta altamente permeabile alle elusioni, specialmente da parte di soggetti interni che abbiano familiarità con i protocolli autorizzativi dell'impresa. L'apprendimento non supervisionato inverte tale logica attraverso modelli di analisi avanzata che valutano la coerenza di ogni transazione rispetto a una molteplicità di variabili: dall'importo alla frequenza dei flussi verso una determinata controparte, fino alla coerenza contrattuale e alla deviazione rispetto al comportamento medio del centro di costo di provenienza. Il sistema apprende la normalità operativa dell'azienda; di conseguenza, ogni pagamento che presenti caratteristiche isolate, posizionandosi al di fuori dei modelli di comportamento abituali, riceve automaticamente un punteggio di rischio elevato, attivando una segnalazione in tempo reale per il team di tesoreria.

La validità operativa di tale approccio trova un riscontro emblematico nel caso aziendale di **Deutsche Bahn**, documentato sulla rivista specializzata di Deutsche Bank (2022). Il gruppo ferroviario tedesco ha integrato un'infrastruttura di controllo in grado di analizzare in modo continuo circa 100.000 disposizioni di pagamento al giorno, assegnando a ciascuna operazione un preciso profilo di rischio basato sull'analisi delle variabili storiche. Questa architettura non si

¹⁸ ACFE, 2022

propone di sostituire la supervisione umana, bensì di ottimizzarne l'efficacia. Il sistema agisce da filtro preventivo, indirizzando l'attenzione degli analisti in via esclusiva verso un perimetro circoscritto di transazioni ad alta criticità. Parallelamente al rafforzamento della sicurezza interna, l'adozione di questi strumenti assicura la piena aderenza alla **normativa Antiriciclaggio (AML)**, garantendo la totale tracciabilità (*auditability*) delle verifiche effettuate e la produzione automatizzata della reportistica probatoria richiesta dagli organi ispettivi.

Tuttavia, l'efficacia pratica di tali modelli non dipende esclusivamente dalla potenza dell'algoritmo, ma dalla capacità del *management* di alimentare l'infrastruttura con un patrimonio informativo eterogeneo. Affinché l'impresa possa realmente superare i limiti dell'analisi tradizionale, le moderne architetture di tesoreria devono agire come veri e propri integratori di flussi.

Un primo e decisivo superamento dei confini contabili coincide con la capacità di valorizzare i **dati interni non strutturati**. Mentre i sistemi gestionali (ERP) tradizionali processano quasi esclusivamente dati strutturati, come date di scadenza e importi, le architetture moderne si avvalgono del *Natural Language Processing* (NLP) per estrarre valore informativo da testi e documenti non strutturati. In un'ottica di *cash management* evoluto, consente al sistema di individuare indicatori anticipatori di rischio o di opportunità, analizzando direttamente i flussi di comunicazione interdipartimentale e le condizioni di pagamento accessorie. Rilevare anticipatamente una modifica dei termini commerciali o l'insorgere di un contenzioso permette di ricalibrare le stime di cassa con largo anticipo rispetto alla manifestazione contabile dell'evento, comprimendo drasticamente i tempi di reazione del management.

Questa spinta verso una maggiore profondità analitica richiede l'inclusione di **variabili esogene e dati alternativi**. Se la tesoreria tradizionale tendeva ad assumere che il futuro dell'impresa fosse una rigida proiezione lineare del proprio storico, i nuovi modelli invece, abbattono tale asimmetria informativa, correlando in tempo reale i flussi di cassa aziendali con indicatori macroeconomici esterni, come: indici di volatilità dei mercati valutari, andamento dei tassi interbancari e metriche settoriali sulla solvibilità media della

clientela. Questa sensibilità alle dinamiche esterne permette al management di abbandonare le logiche puramente reattive a favore di una pianificazione predittiva e adattiva, in cui il piano di liquidità si rimodula dinamicamente al variare delle condizioni di mercato.

Affinché questa mole di informazioni si traduca in valore strategico diviene essenziale l'adozione di una solida architettura di **Data Governance**. In un ambiente operativo digitalizzato, l'obiettivo della funzione finanziaria non si deve basare sulla conformità formale del dato, ma focalizzarsi sulla sua architettura e standardizzazione. L'impiego di dati qualitativamente carenti finirebbe per inficiare l'intero impianto predittivo, producendo distorsioni strutturali nelle stime di liquidità. In tale prospettiva, lo standard internazionale **ISO 20022** assume una valenza determinante: superando la concezione di semplice protocollo informatico, si configura come l'infrastruttura portante per assicurare la qualità dei dati richiesta dai modelli algoritmici. L'adozione di questo principio permette infatti di incorporare, direttamente nel flusso di pagamento, dati strutturati e ad alto valore aggiunto, quali causali analitiche e riferimenti fiscali univoci. Questa ricchezza informativa permette al sistema di decodificare il contesto reale di ogni transazione, spingendo i tassi di riconciliazione automatica delle partite aperte, fino a raggiungere un livello di automazione pressoché integrale (*Straight-Through Processing*). Solo garantendo l'assoluta pulizia del dato alla fonte si evita il rischio di elaborare proiezioni ambigue, trasformando l'informazione in un *asset* decisionale pienamente affidabile e propedeutico all'introduzione dei sistemi di esecuzione autonoma.

Il raggiungimento di gestione del dato consente l'utilizzo di sistemi a esecuzione autonoma, grazie all'impiego dei modelli di **Reinforcement Learning** (Apprendimento per Rinforzo). Per comprenderne il valore, occorre partire da una constatazione di natura gestionale. I modelli analitici esaminati in precedenza operano fondamentalmente su serie storiche statiche, producendo *output* che descrivono uno scenario passato o presente. Quindi non risultano essere strutturati per ottimizzare in modo dinamico sequenze di decisioni interdipendenti nel tempo. Tuttavia, questa è esattamente la natura del problema

affrontato quotidianamente dalla direzione finanziaria: la scelta su quanta liquidità mantenere in forma liquida e quanta investire a breve termine, modifica inevitabilmente il contesto e le opzioni strategiche dei giorni successivi.

Il modello di *Reinforcement Learning* risolve alla radice tale complessità strutturale. Infatti, anziché limitarsi a replicare schemi pregressi, il sistema opera all'interno di scenari simulati, valutando le diverse opzioni allocative in base a un obiettivo strategico predefinito (la cosiddetta funzione di massimizzazione del valore). Attraverso un processo di ottimizzazione continua basato su innumerevoli simulazioni finanziarie, il modello impara a massimizzare il rendimento complessivo nel medio-lungo periodo, individuando in totale autonomia la strategia ottimale. Questa logica si avvicina a un processo di apprendimento empirico secondo la quale, accumulando esperienza sui risultati delle proprie scelte allocative, il sistema sviluppa una competenza decisionale capace di superare i limiti di rigidità delle tradizionali *policy* statiche.

Nell'ambito della tesoreria, l'applicazione di questo modello riguarda **l'ottimizzazione dinamica della liquidità**, intesa come il bilanciamento continuo tra la riserva precauzionale e il portafoglio di investimenti. La determinazione della quota di cassa da mantenere inattiva rispetto a quella da impiegare in strumenti monetari (come, ad esempio, le *commercial paper* a brevissima scadenza) costituisce, sotto il profilo quantitativo, un sofisticato modello di ottimizzazione stocastica su più orizzonti temporali. In questo scenario, il tesoriere deve governare la tensione tra il costo opportunità della liquidità inoperosa e il rischio di illiquidità derivante da una gestione troppo aggressiva delle riserve. La solidità di un approccio basato sull'apprendimento per rinforzo è attestata dalle analisi di Aldasoro e Desai (2025) per la Bank of Canada. La ricerca evidenzia come l'impiego di agenti intelligenti permetta di coniugare il rigore delle policy cautelative con l'efficienza nell'allocazione delle riserve, anche in contesti operativi caratterizzati da estrema complessità.

Oltre all'ottimizzazione della liquidità, questa tecnologia trova una necessaria integrazione nella **protezione della liquidità dai rischi di mercato**, con particolare riferimento alla gestione dinamica del rischio di cambio (*FX*

hedging). In un'ottica di *cash management* integrato, la volatilità valutaria non rappresenta infatti un elemento isolato, bensì una variabile critica capace di alterare profondamente la disponibilità di cassa prevista e la precisione del *forecast* monetario. Tradizionalmente, la gestione di questo rischio è affidata a *policy* rigide. La tesoreria stabilisce ex-ante una percentuale di copertura fissa sui flussi attesi e sottoscrive strumenti derivati, come i contratti *forward*, mantenendoli in portafoglio fino alla loro scadenza. Tale approccio, per quanto prudente, risulta spesso insufficiente, poiché non recepisce l'evoluzione dei tassi di cambio né le mutazioni nelle correlazioni tra le valute nel corso del tempo. L'impiego dell'apprendimento per rinforzo abilita, invece, una gestione adattiva e continua. Pertanto, attraverso il monitoraggio in tempo reale delle variabili di mercato, il modello regola appositamente l'esposizione valutaria decidendo se incrementare, mantenere o liquidare le posizioni aperte. Tale approccio permette di delineare una strategia dinamica volta a massimizzare il valore dei flussi attesi, ottimizzando simultaneamente il profilo dei costi di copertura.

Recenti evidenze empiriche confermano come tale flessibilità operativa accresca l'efficacia della copertura rispetto alle strategie convenzionali, in particolare durante fasi di marcata instabilità valutaria¹⁹. Sotto il profilo gestionale, i vantaggi risultano parimenti significativi, dato che l'integrazione di sistemi di supporto dinamico ha permesso di contenere gli oneri di *hedging* in una misura compresa tra l'8% e il 15%²⁰. In un mercato dei cambi caratterizzato da oscillazioni repentine dei cambi generano incertezze che possono compromettere la pianificazione finanziaria, la capacità di monitorare costantemente gli scenari e identificare i tempi di esecuzione ottimali garantisce un'agilità decisionale che i processi manuali non sono strutturalmente in grado di eguagliare.

In definitiva, questi modelli esaminati non devono essere interpretati come soluzioni fra loro isolate, quanto piuttosto come componenti complementari di un'architettura di tesoreria evoluta.

¹⁹ Deng et al., 2016

²⁰ Citigroup, 2025

CAPITOLO 2 - L'ANALISI ECONOMICO-GESTIONALE: COSTI, BENEFICI E ROI DELL'IA

2.1 Il Total Cost of Ownership: Anatomia dell'Investimento

La letteratura sull'IT Management ha da tempo documentato come i costi effettivi di adozione di sistemi informatici complessi comportino, oltre al costo diretto per l'acquisizione del sistema, una serie di costi indiretti come l'integrazione dei dati e la riorganizzazione dei processi. Per questo motivo viene in aiuto il **Total Cost of Ownership (TCO)**, che permette di catturare la reale struttura economica dell'investimento, poichè si tratta di un framework che trasforma la valutazione da un esercizio di *pricing* puntuale a un'analisi economica sul ciclo di vita della soluzione.

2.1.1 Framework Analitico TCO per Soluzioni AI

L'origine del concetto di Total Cost of Ownership è riconducibile alle ricerche di Gartner alla fine degli anni Ottanta, con i contributi di Bill Kirwin e Jim Livingston (1987). Tale framework fu inizialmente sviluppato per stimare il costo reale della gestione di un personal computer aziendale al di là del solo prezzo d'acquisto. Nel corso dei decenni successivi, il framework si è però progressivamente evoluto fino a diventare lo strumento analitico di riferimento per la valutazione degli investimenti tecnologici d'azienda, esteso ad oggi con efficacia anche alle soluzioni AI. La sua utilità manageriale deriva non da una formula matematica in sé, ma dalla capacità di rendere espliciti i costi che la valutazione tradizionale tende a trascurare.

Per quanto riguarda le soluzioni di intelligenza artificiale applicate al cash management, il TCO può essere articolato lungo tre dimensioni fondamentali, indipendenti ma complementari tra di loro, ovvero: dimensione temporale, dimensione della visibilità e dimensione funzionale

Categorizzazione Multi-Dimensionale

Il valore del TCO risiede precisamente nella sua capacità di scomporre un investimento apparentemente unico, in componenti di costi aventi natura differente, governati da logiche temporali, organizzative e tecnologiche distinte.

Per un investimento in AI applicata alla tesoreria, tale scomposizione diventa necessaria data la diffusione del **modello SaaS (*Software as a Service*)** che ha reso le strutture di costo meno intuitive rispetto all'epoca tradizionale, determinando una percezione attenuata dell'impatto economico totale a causa della natura frammentata dei canoni di servizio.

Dimensione Temporale: CAPEX vs. OPEX

La prima dimensione di analisi è quella temporale, fondata sulla distinzione tra **investimenti in conto capitale (CAPEX - *Capital Expenditure*)** e **costi operativi (OPEX - *Operating Expenditure*)**. Nonostante questa distinzione rappresenti un concetto basilare della finanza d'impresa, essa ha assunto una maggiore valenza strategica con l'avvento del *cloud computing*, il quale ha ridefinito radicalmente la tempistica e la natura degli esborsi legati all'acquisizione di asset tecnologici.

Nel paradigma tradizionale *on-premise* l'azienda sostiene un costo iniziale concentrato e significativo per l'acquisto di licenze perpetue e hardware dedicato. Tale investimento, classificato come immobilizzazione immateriale, nel rispetto dei principi contabili internazionali IAS/IFRS, comprende sia il valore di tali asset sia gli oneri legati ai servizi di *system integration* necessari alla messa in opera. L'investimento veniva successivamente ammortizzato lungo la vita utile stimata del bene, generalmente compresa tra i tre e i cinque anni. Sotto il profilo finanziario, il TCO si presentava dunque fortemente asimmetrico: un massiccio assorbimento di cassa iniziale, seguito da costi operativi ricorrenti più contenuti (manutenzione e aggiornamenti), incidenti indicativamente per circa il 18-22% del valore della licenza su base annua.

La transizione verso il modello SaaS costituisce oggi lo standard per le soluzioni di IA in tesoreria, assorbendo circa il 78% delle nuove implementazioni in ambito aziendale, capovolge questa dinamica. L'investimento iniziale (CAPEX) si riduce drasticamente, limitandosi alle sole spese di configurazione del sistema. La spesa principale si trasforma così in un costo operativo ricorrente (OPEX), calcolato sotto forma di canoni periodici che variano in base all'intensità d'uso della piattaforma o al numero di dipendenti abilitati. A livello di bilancio, le implicazioni sono profonde, infatti i canoni di servizio gravano per intero sul

Conto Economico dell'esercizio di competenza, negando la possibilità di diluirne l'impatto tramite la quota di ammortamento. Per le direzioni finanziarie soggette a parametri stringenti di redditività, l'impossibilità di capitalizzare l'investimento costituisce un elemento imprescindibile nella scelta dell'infrastruttura tecnologica.

Per valutare correttamente questo genere di investimenti, la prassi manageriale adotta convenzionalmente un orizzonte temporale di tre anni²¹. La misurazione del TCO triennale può essere concettualizzata attraverso la somma dell'esborso iniziale (CAPEX al tempo zero), dei costi operativi ricorrenti (la sommatoria degli OPEX per i tre esercizi), a cui vanno necessariamente aggiunti i costi latenti (*Hidden costs*) e i costi opportunità (*Opportunity costs*).

Proprio la componente dei costi latenti richiede un'analisi rigorosa, trattandosi della voce maggiormente soggetta a sottostima in sede di preventivo. A conferma di ciò, un'indagine di Deloitte (2024) condotta su oltre 120 direttori finanziari europei ha evidenziato come il 68% delle organizzazioni abbia registrato significativi sforamenti di budget nei progetti di trasformazione IA, generati in gran parte dalle attività di preparazione dei dati, dal *change management* e dagli ostacoli emersi durante l'integrazione con i vecchi sistemi ERP.

Dimensione della Visibilità: Costi Espliciti e Costi Impliciti

La dimensione della visibilità si focalizza sul **grado di trasparenza dei costi**, distinguendo tra componenti **esplicite** ed **implicite**, che emergono solo nel corso dell'implementazione o addirittura nella fase di regime operativo. È proprio questa seconda categoria a rappresentare la causa principale dello scostamento tra il budget iniziale e i costi effettivamente rilevati a consuntivo.

Tra le componenti implicite più ricorrenti nei progetti AI per il cash management, assume un ruolo centrale l'impiego di risorse interne appartenenti alle funzioni Finance e IT per le attività di configurazione e collaudo del sistema. Tali oneri restano spesso latenti in quanto vengono assorbiti dai centri di costo ordinari dei dipartimenti, anziché essere imputati direttamente al progetto. Un ulteriore elemento critico è rappresentato dal ***parallel run***, dato che, per un

²¹ Forrester Research, 2023

periodo che oscilla tra i tre e i sei mesi, l'impresa deve mantenere attivi i processi tradizionali parallelamente alla nuova piattaforma per garantirne la validazione, raddoppiando di fatto l'impegno operativo.

Infine, l'analisi deve considerare il *vendor lock-in premium*, ovvero l'onere implicito derivante dalla perdita di flessibilità strategica. Una volta che i processi e i dati critici sono stati migrati sull'architettura del fornitore prescelto, l'azienda accetta implicitamente un differenziale di costo legato alla rinuncia alla possibilità di cambiare fornitore nel breve periodo, date le elevate barriere all'uscita²².

Dimensione Funzionale: Costi Tecnologici, Organizzativi e di Transizione

La dimensione funzionale classifica i costi in base all'area d'intervento che li genera, distinguendo tra una **componente tecnologica** (licenze, infrastruttura, integrazione sistemi), una **componente organizzativa** (formazione, gestione del cambiamento, ridisegno dei processi) e una **componente di transizione** (costi temporanei associati al passaggio dal vecchio al nuovo sistema). Questa divisione è analiticamente utile perché ciascuna categoria risponde a logiche di controllo e ottimizzazione distinte.

Infatti, la componente tecnologica è determinata dalla scelta del fornitore e dal perimetro funzionale; quella organizzativa dipende dalla maturità digitale del team finance e dalla cultura aziendale; quella di transizione è funzione della complessità dei sistemi preesistenti e della metodologia di implementazione adottata.

2.1.2 Costi Diretti Tecnologici

Licenze Software AI

Le licenze software rappresentano la voce di costo più esplicita e, tipicamente, il fulcro delle negoziazioni con i fornitori in fase di *vendor selection* (selezione dei fornitori). Attualmente, il mercato delle soluzioni di intelligenza artificiale per la tesoreria offre tre principali architetture di *pricing*.

Il modello a **licenza perpetua con canone di manutenzione** rappresenta

²² Forrester Research, 2023

l'eredità del paradigma on-premise e mantiene una presenza residuale soprattutto nei settori altamente regolamentati, come quello bancario e assicurativo, dove i requisiti di *data residency* (localizzazione dei dati) e sovranità delle informazioni, rendono problematica la migrazione in cloud. In questo modello, l'acquisto iniziale della licenza comporta un esborso che varia tra gli 80.000€ ed i 300.000€ per soluzioni di cash management, a cui si aggiunge un canone annuo di manutenzione pari al 18-22% del prezzo di acquisto. Se da un lato l'azienda si garantisce la proprietà della soluzione, evitando così l'acquisto di abbonamenti, dall'altro lato bisogna però considerare l'elevato assorbimento di cassa iniziale e un forte rischio di obsolescenza tecnologica.

In contrapposizione si pone il modello **SaaS a canone ricorrente**, diventato ormai lo standard per le implementazioni di nuova generazione. La struttura tariffaria si articola tipicamente su due variabili: il numero di utenti attivi e il volume transazionale gestito dalla piattaforma. Per un'impresa di medie dimensioni (fatturato compreso tra €100M e €500M), i benchmark di mercato aggregati da Gartner (2023) e Forrester (2023) indicano un range di spesa annua compreso tra €80.000 e €200.000, con una mediana intorno a €95.000 annui per il segmento considerato, con una correlazione positiva con il fatturato aziendale (coefficiente $r=+0,68$ su campione di 200 aziende). Il punto critico di questo modello è il fenomeno dell'*accumulo dei costi ricorrenti*. Il canone SaaS, che appare contenuto nell'anno uno, può diventare, su un orizzonte di cinque-sette anni, meno vantaggioso di una licenza perpetua, specialmente se non si capitalizzano pienamente i benefici attesi nella fase iniziale.

Il modello **consumption-based** (o *pay-per-use*) rappresenta il modello più recente e concettualmente più allineato alla logica del valore generato, dato che l'azienda paga in proporzione all'utilizzo effettivo della piattaforma. Pur eliminando il rischio di pagare per capacità inespressa, tale struttura tariffaria introduce una forte volatilità nel budget operativo. Per aziende caratterizzate da una marcata stagionalità, come un *retailer* con picchi transazionali nell'ultimo trimestre, questo modello può generare fatture mensili con scostamenti nell'ordine del 200-300%, complicando notevolmente la pianificazione finanziaria della tesoreria stessa.

Indipendentemente dalla tipologia contrattuale scelta, i fattori che determinano il posizionamento di un'impresa all'interno di questi range tariffari sono identificabili nel numero di moduli funzionali attivati (ogni modulo aggiuntivo comporta un incremento del canone stimabile tra €10.000 e €30.000 annui), nel modello di deployment scelto (on-premise o cloud privato comporta un sovrapprezzo del 30-50% rispetto alla soluzione cloud pubblica standard) e il livello di SLA (*Service Level Agreement*) contrattualizzato, con la distinzione tra supporto base (8x5, orario lavorativo) e premium (24x7, con garanzie di disponibilità del 99,9% e tempi di risposta garantiti) che incide tipicamente per un ulteriore 15-20% sul canone complessivo.

Hardware e Infrastruttura

La componente hardware ed infrastruttura ha subito una trasformazione radicale nell'ultimo decennio, al punto da risultare oggi una voce di costo spesso marginale o indiretta nelle analisi del TCO per l'intelligenza artificiale in tesoreria. Questa evoluzione è una conseguenza della diffusione del *cloud computing*, determinando una traslazione contabile dell'investimento dallo Stato Patrimoniale dell'azienda acquirente al Conto Economico, sotto forma di costi operativi inclusi nel canone di abbonamento.

Le implementazioni secondo il modello **Full SaaS** rappresentano la modalità di erogazione prevalente, la componente hardware è di fatto azzerata per l'impresa, poiché l'intera capacità computazionale necessaria all'addestramento e all'esecuzione dei modelli di *machine learning* risiede sui server del fornitore, il quale ne garantisce anche la scalabilità e la continuità operativa.

Una dinamica differente è caratterizzata dalle **implementazioni ibride**, le quali combinano componenti cloud per l'elaborazione dei modelli AI con sistemi installati in sede per la gestione dei flussi bancari sensibili. Questa configurazione, frequente nelle organizzazioni soggette a stringenti requisiti di **data residency** (localizzazione dei dati) imposti dal GDPR o da politiche interne di sicurezza, comporta costi aggiuntivi stimabili tra 10.000 e 30.000 euro per la configurazione del *middleware* di integrazione e dei *gateway* applicativi, a cui si aggiunge un onere annuo di gestione compreso tra 5.000 e 10.000 euro.

Il modello **full on-premise** nonostante rappresenti una quota marginale del

mercato (stimata al 12% delle nuove implementazioni secondo McKinsey nel 2024), continua a sussistere, principalmente nel settore bancario e in alcune grandi corporate con politiche di sicurezza IT particolarmente conservative. In questo scenario, i costi infrastrutturali tornano a essere significativi e richiedono un investimento iniziale in hardware dedicato, come server GPU e unità di *storage* ad alte prestazioni, quantificabile tra 40.000 e 80.000 euro. Oltre a un costo annuo di manutenzione, stimabile tra 10.000 e 15.000 euro, tale modello impone di considerare anche i consumi energetici e i sistemi di raffreddamento dei *data center*, voci di spesa spesso trascurate nelle analisi preliminari ma capaci di incidere sensibilmente sulla redditività dell'investimento nel lungo periodo.

Consulenza e Implementazione

La componente di consulenza e implementazione rappresenta, una delle voci di costo più rilevanti e al contempo più variabili dell'intero investimento. A differenza dei canoni software, la cui struttura è codificata nei listini dei fornitori, i costi di consulenza dipendono da una molteplicità di fattori, legati alla complessità organizzativa, alla qualità dei sistemi informatici preesistenti e alla disponibilità di competenze interne.

Un tipico progetto di implementazione di una soluzione AI per il cash management si articola tipicamente in tre macro-fasi, ciascuna con un proprio assorbimento di risorse consulenziali. Troviamo la fase di ***discovery e design*** (di scoperta e progettazione), incentrata sull'analisi dei processi esistenti e progettazione dell'architettura di integrazione; la fase di ***build*** (costruzione), che include la personalizzazione della piattaforma, sviluppo dei connettori verso i sistemi ERP e bancari e l'addestramento iniziale dei modelli); arrivando alla fase di ***testing e go-live*** (avvio operativo), che sarebbe il momento dedicato alla validazione dei risultati, formazione degli utenti, affiancamento operativo nella fase di avvio).

La durata e il costo complessivo di questo percorso variano in funzione della dimensione aziendale e della complessità dell'implementazione. Stando ai *benchmark* aggregati da PwC (2023) e KPMG (2024), per le piccole e medie imprese (con fatturato inferiore a 100 milioni di euro) l'integrazione di una

soluzione SaaS standard richiede solitamente dai tre ai cinque mesi, con un esborso compreso tra 20.000 e 50.000 euro. Nel segmento *mid-market* (tra 100 e 500 milioni di euro), la necessità di maggiori personalizzazioni innalza i costi in un intervallo tra 50.000 e 120.000 euro, su un orizzonte temporale di cinque-otto mesi. Fisiologicamente più oneroso risulta il comparto aziendale, dove l'esigenza di un *rollout* (distribuzione su larga scala) internazionale dilata i tempi fino a diciotto mesi, portando le spese di consulenza a toccare picchi compresi tra 150.000 e 400.000 euro.

Due fattori strutturali emergono dall'analisi di regressione condotta da McKinsey (2024) su un campione di 200 progetti di implementazione AI in ambito finance come i principali *driver* del costo consulenziale. Il primo è la **complessità dei sistemi legacy preesistenti**, secondo il quale ogni sistema aggiuntivo che richiede integrazione con la nuova piattaforma AI incrementa il costo di consulenza di circa il 12% (coefficiente $\beta=+0,42$, $p<0,01$). Il secondo è la **portata geografica dell'implementazione**, che comporta un aumento dei costi del 50-80% rispetto a un'implementazione un'iniziativa locale, riconducibile alla necessità di gestire requisiti normativi differenti, formati da dati bancari eterogenei tra paese e paese, e la complessità organizzativa della gestione di un progetto con fusi orari e culture aziendali diverse.

2.1.3 Costi Organizzativi e Change Management

Investimento in Formazione

L'adozione di una piattaforma di intelligenza artificiale per la tesoreria non si basa sulla sola installazione del software. Infatti, come ampiamente documentato dalla letteratura sull'*IT adoption*, il fallimento dei progetti tecnologici deriva raramente da deficit all'applicativo di software, risultando quasi sempre imputabile a un inadeguato investimento formativo sul capitale umano²³. Per governare efficacemente le nuove soluzioni, il fabbisogno didattico si deve basare su diverse figure aziendali. I principali fruitori del sistema, ovvero i *cash manager* e gli analisti, necessitano di sviluppare una solida ***data literacy***

²³ Davenport, 2018; Prosci, 2023

(alfabetizzazione ai dati) per interpretare gli output algoritmici e per comunicare con i fornitori. Tale preparazione richiede laboratori pratici su casi d'uso reali per circa 20-30 ore, con un costo che varia tra 1.500 e 3.000 euro per risorsa²⁴. Parallelamente, figure come il CFO e i *controller* non necessitano di competenze tecnico-operative, bensì di sessioni *executive* (circa 8 ore, per un costo di 500-1.000 euro a partecipante) mirate alla valutazione dei KPI di sistema e alla comunicazione del valore strategico al Consiglio di Amministrazione. Non va trascurato il dipartimento IT interno dato che i tecnici che si occupano del mantenimento dell'infrastruttura devono padroneggiare le architetture AI e le procedure di *troubleshooting* (risoluzione dei problemi) sulle API bancarie, un percorso avanzato che assorbe tra le 40 e le 80 ore, con costi di certificazione compresi tra 3.000 e 5.000 euro.

Per suddividere correttamente questo investimento, la prassi manageriale suggerisce di allocare un budget formativo pari all'8-12% del costo annuo delle licenze software²⁵. Su un canone SaaS di 100.000 euro, ciò si traduce in un accantonamento di 8.000-12.000 euro annui, una cifra che, in assenza di un'esplicita pianificazione, rischia di subire tagli operativi. A questa spesa si somma il costo opportunità, quantificabile moltiplicando il costo orario medio del personale per le ore sottratte all'operatività ordinaria. A titolo di esempio, per un team di dieci risorse con un costo misto di 50 euro l'ora, un programma di 25 ore genera un onere implicito di 12.500 euro, valore che deve essere integrato nella rappresentazione del TCO.

L'analisi economica deve infine includere inoltre, l'impatto della curva di **apprendimento post-go-live** (successiva all'avvio operativo). Nei primi mesi di utilizzo, l'adattamento ai nuovi *workflow* (flussi di lavoro) e lo sviluppo di fiducia verso l'algoritmo provocano una temporanea flessione della produttività stimabile tra il 20% e il 30%²⁶. Considerando un team di tre *cash manager* con un costo annuo complessivo di 180.000 euro, una contrazione dell'efficienza del 25% per un trimestre genera un costo occulto di circa 11.250 euro. Si tratta di una passività latente che raramente trova spazio nel *business case* del fornitore,

²⁴ Deloitte, 2023

²⁵ Deloitte, 2023

²⁶ Prosci, 2023

ma che la direzione finanziaria è tenuta a calcolare per ottenere una visione realistica del progetto.

Change Management e Gestione delle Resistenze

La gestione del cambiamento, o ***change management***, costituisce la voce di costo più sottostimata nei budget di trasformazione digitale, pur rappresentando la variabile più determinante per il successo dell'iniziativa. Un'indagine di Prosci (2023) condotta su un campione di 450 organizzazioni evidenzia che i progetti tecnologici con un investimento in ***change management*** inferiore al 10% del budget complessivo registrano un tasso di successo fermo al 35%, mentre quelli che superano la soglia del 15% raggiungono il 72%, giustificando ampiamente l'esborso addizionale.

Le resistenze in ambito tesoreria presentano tuttavia peculiarità uniche rispetto ad altre transizioni digitali. L'introduzione di algoritmi predittivi in una funzione storicamente fondata sull'***expert judgment*** innesca nei professionisti reazioni contrastanti. Per questo motivo, si nota come possa emergere una forte ***automation anxiety*** (ansia da automazione) legata al timore che la macchina eroda il livello decisionale del ***cash manager***; ma allo stesso tempo, si manifesta uno scetticismo verso risultati complessi che non si è ancora in grado di determinare. Tali dinamiche, ampiamente documentate nella letteratura di ***organizational behavior*** (comportamento organizzativo)²⁷, esigono interventi mirati che generano specifiche componenti di costo.

Inizialmente, la comunicazione interna assorbe un costo opportunità stimabile tra 10.000 e 20.000 euro, legato al tempo sottratto al ***management senior***. Dopo si rende spesso necessario un ***coaching*** individuale per i soggetti più resistenti (tipicamente il 5-10% della forza lavoro), con un costo variabile tra 1.500 e 6.000 euro. Infine, l'implementazione di sistemi di incentivazione per gli ***early adopters*** (i primi adottanti) risulta fondamentale per innescare meccanismi di ***peer influence*** (influenza tra pari), richiedendo un budget iniziale compreso tra 2.000 e 5.000 euro per il gruppo pilota.

Per comprendere correttamente questo aggregato, il framework di Prosci suggerisce di allocare tra il 15% e il 20% del valore totale del progetto. Su un

²⁷ Davenport & Ronanki, 2018; Orlikowski, 2000

investimento tecnologico di 200.000 euro, il budget ottimale si colloca dunque tra 30.000 e 40.000 euro. Tale parametro costituisce un punto di riferimento flessibile di cui le aziende con una forte cultura innovativa necessitano di risorse inferiori, mentre le organizzazioni caratterizzate da gerarchie rigide o da precedenti fallimenti in ambito IT richiedono un impiego di maggiori risorse.

2.1.4 Costi di Integrazione Dati e Sistemi Legacy

Data Quality e Preparazione

Come già discusso nel primo capitolo in merito al paradigma del “*garbage in, garbage out*”, l'affidabilità di un modello di *machine learning* è fortemente vincolata alla bontà del patrimonio informativo che lo alimenta. Nelle soluzioni di *cash forecasting*, l'impiego di un *dataset* storico viziato da errori di categorizzazione o inconsistenze nei formati si traduce in previsioni distorte, innescando il rischio che il *management* assuma decisioni di finanziamento basate su risultato equivoci.

La letteratura specialistica quantifica il costo della preparazione dei dati tra il 30% e il 40% del tempo totale dedicato a un progetto di implementazione AI²⁸. In termini monetari, questa percentuale si traduce in un esborso compreso tra 15.000 e 40.000 euro per le PMI, e tra 50.000 e 150.000 euro per le grandi organizzazioni, con una variabilità che dipende dallo stato qualitativo di partenza. L'evidenza empirica raccolta da Deloitte (2024) conferma questa criticità, indicando che il 68% delle aziende classifica la ***data quality*** come il principale scostamento imprevisto nei budget di trasformazione tecnologica.

Per attenuare tale rischio, l'azienda deve affrontare un rigoroso processo di ***data engineering*** articolato in quattro fasi progressive ma strettamente interconnesse. Il processo si apre con un ***audit*** (revisione) dei flussi transazionali (estratti conto, registrazioni ERP) per mappare valori mancanti, duplicati o formati incoerenti. Segue poi la fase di ***cleaning*** (pulizia e standardizzazione) che richiede una profonda conoscenza dei processi aziendali per distinguere le reali anomalie dai semplici errori di classificazione. Successivamente si procede all'**arricchimento**

²⁸ IBM Data & AI Economics, 2024; Gartner, 2023

del dataset, integrando variabili esterne che potenziano il potere predittivo del modello, come gli indicatori di stagionalità o i tassi di cambio. Il ciclo si conclude con la **fase di validazione**, in cui il *dataset* depurato viene testato su campioni storici per certificarne la coerenza statistica.

Questa sequenza di attività genera non solo costi diretti, legati al tempo del personale interno o dei consulenti esterni, ma anche oneri indiretti derivanti dal ritardo nel *go-live* della soluzione. Trascurare la pianificazione di questa fase progettuale non elimina il problema, ma lo trasferisce drammaticamente all'interno dell'operatività quotidiana, in quanto le lacune qualitative dei dati emergeranno sotto forma di anomalie inspiegabili nei *forecast*, minando la fiducia degli utenti e compromettendo l'adozione effettiva del sistema.

Integrazione con Sistemi Esistenti

I costi di transizione si basano sul lavoro tecnico necessario per innestare la nuova piattaforma di intelligenza artificiale all'interno del tessuto informativo preesistente dell'organizzazione. L'architettura di integrazione si sviluppa attorno **al consolidamento dei flussi certi e all'anticipazione delle dinamiche prospettiche**. Il flusso informativo principale del modello predittivo è garantito dall'interscambio con il sistema ERP (quali SAP S/4HANA, Oracle o Microsoft Dynamics), che forniscono la base contabile e i piani di pagamento con le piattaforme bancarie. Queste ultime, sfruttando protocolli di *open banking* (come EBICS 3.0 o la rete SWIFT), assicurano quella visibilità in tempo reale sui saldi *intraday*. Per poter migliorare la precisione del *forecast*, l'ecosistema deve intercettare le operazioni aziendali prima che generino un debito o un credito formale. Nello specifico, **i sistemi CRM** (es. Salesforce) diventano cruciali per evidenziare il lato degli incassi, traducendo le probabilità di conversione della *pipeline* commerciale in liquidità futura; specularmente, **i software di procurement** (approvvigionamento) permettono all'IA di anticipare tempestivamente i deflussi di cassa originati dalla *supply chain*.

Il costo economico di questa architettura dipende dal grado di modernità degli applicativi di partenza. Qualora i sistemi espongano API standardizzate e pre-documentate, lo sforzo si limita alla configurazione di connettori nativi forniti dal *vendor* dell'IA, richiedendo un esborso contenuto tra 5.000 e 15.000 euro.

Opposto è lo scenario in cui l'impresa operi su sistemi legacy sviluppati internamente negli anni Novanta o Duemila, dato che l'assenza di interfacce moderne e l'uso di formati proprietari impongono lo sviluppo di un *middleware* (software di intermediazione) personalizzato, facendo lievitare i costi in un intervallo compreso tra 30.000 e 80.000 euro, con un proporzionale dilatamento dei tempi di progetto.

Questo fenomeno di sovrapprezzo è stato formalizzato da Forrester Research (2023) attraverso il concetto di *integration tax* (tassa di integrazione). Nelle implementazioni aziendali, l'adattamento dei sistemi assorbe mediamente il 25-35% della spesa totale del software. Tale incidenza subisce impennate drammatiche, toccando punte del 50-70%, in quei contesti organizzativi che MuleSoft (2024) definisce *spaghetti architecture* (architetture a groviglio), ovvero ecosistemi IT caotici caratterizzati da oltre quindici applicativi frammentati e disconnessi. Per la direzione finanziaria, questi dati convergono verso una raccomandazione strategica secondo la quale prima di deliberare l'adozione di un algoritmo avanzato, è essenziale condurre una revisione apposita sulla maturità del proprio comparto informatico. Sottovalutare la rigidità dell'infrastruttura rischia infatti di rendere i costi di integrazione superiori a quelli della soluzione AI stessa, confermandosi come la prima causa di sfioramento dei budget nella trasformazione tecnologica della tesoreria.

2.2 I Benefici dell'AI: Creazione di Valore Multi-Dimensionale

L'analisi della struttura dei costi affrontata nel paragrafo precedente offre solo una visione parziale della valutazione economica richiesta a un CFO nel contesto dell'intelligenza artificiale per la tesoreria. La reale efficacia dell'investimento, ovvero ciò che trasforma un mero esborso in un asset strategico, risiede nella capacità di rilevare i benefici generati dalla tecnologia a livello operativo e decisionale della funzione finanziaria. Questo processo di valutazione non può limitarsi a un mero esercizio contabile, ma impone l'adozione di un framework capace di rendere espliciti quei vantaggi che, pur non riflettendosi direttamente nel conto economico, modificano strutturalmente le capacità organizzative dell'impresa e ne rafforzano la posizione competitiva nel medio periodo.

2.2.1 Framework di Classificazione dei Benefici

La letteratura sull'IT Business Value ha elaborato molteplici framework per classificare i ritorni generati dagli investimenti tecnologici. Tra questi, il modello proposto da Mooney, Gurbaxani e Kraemer (1996) offre la struttura analitica più adeguata a interpretare il valore generato dall'intelligenza artificiale in tesoreria. Tale modello categorizza il valore tecnologico in base all'impatto prodotto sull'organizzazione dall'efficienza derivante **dall'automazione dei processi** (*Automational*), alla maggiore consapevolezza decisionale garantita da **dati di qualità** superiore (*Informational*), fino alla ridefinizione strutturale delle **logiche operative e competitive** dell'impresa (*Transformational*). L'utilità di questo approccio risiede nel fatto che ordina i benefici non per semplice natura contabile, ma per il meccanismo causale attraverso cui la tecnologia produce valore, in quanto possa portare la sostituzione del lavoro umano ripetitivo, il miglioramento qualitativo delle informazioni a supporto del management e la ridefinizione dell'assetto organizzativo e competitivo dell'impresa.

Applicato al dominio specifico del cash management, tale modello necessita di essere integrato con una quarta dimensione, definita **Financial**, indispensabile per catturare l'impatto diretto dell'intelligenza artificiale sulle voci di bilancio. La riduzione dei costi finanziari e l'ottimizzazione del capitale circolante rappresentano infatti effetti che, pur derivando da efficienze operative e decisionali, possiedono una tracciabilità diretta da meritare una trattazione dedicata. Il framework risultante si sviluppa quindi su quattro livelli gerarchici e complementari (*Automational*, *Informational*, *Transformational*, *Financial*), ciascuno dei quali risulta utile per evidenziare una corretta creazione di valore, differenziandosi per grado di tangibilità, orizzonte temporale e misurabilità.

La distinzione di queste categorie ha implicazioni dirette sulla metodologia di misurazione e sulla costruzione del business case che il CFO presenta al Consiglio di Amministrazione. I **benefici operativi (Automational)** e **finanziari (Financial)** risultano quantificabili con precisione attraverso metriche standardizzate, come la riallocazione degli FTE (Full-Time Equivalent) o le variazioni del Capitale Circolante Netto, prestandosi a una monetizzazione in modo diretto. I vantaggi di natura **informativa (Informational)** richiedono

un passaggio intermedio, poiché il loro impatto non si valuta sull'output del sistema informatico, ma sulla maggiore efficacia delle decisioni strategiche che ne derivano. Infine, i ritorni legati alla **trasformazione aziendale (Transformational)** sfuggono a una valorizzazione economica diretta, ma incidono sulle capacità dinamiche dell'organizzazione, generando un vantaggio competitivo duraturo, la cui sostenibilità è strettamente correlata alla difficoltà di imitazione da parte dei concorrenti²⁹.

2.2.2 Benefici Automational: Efficienza Operativa

La categoria *Automational* identifica quella classe di benefici che si materializza attraverso la sostituzione, parziale o integrale, del lavoro umano ripetitivo con processi automatizzati. In tesoreria, questa dimensione risulta particolarmente rilevante poiché la funzione è storicamente caratterizzata da un elevato assorbimento di risorse umane qualificate in attività a forte contenuto esecutivo, quali il caricamento manuale degli estratti conto, le riconciliazioni bancarie, la generazione di report di posizione liquida e la predisposizione dei *forecast* settimanali su fogli di calcolo. La loro automatizzazione, di conseguenza, non rappresenta un semplice risparmio di costo, bensì una strategica riallocazione del capitale umano verso mansioni a maggiore intensità cognitiva.

Riduzione dei Costi Labor e Riallocazione degli FTE

Il meccanismo di creazione di valore sottostante ai **benefici labor** (legati al personale) non risiede nella riduzione del numero complessivo di addetti alla tesoreria, bensì nella redistribuzione qualitativa del tempo lavorativo disponibile. L'evidenza empirica raccolta da Accenture (2023) su un campione di 180 funzioni di tesoreria di grandi imprese europee indica che, nelle organizzazioni che hanno integrato soluzioni AI per il *cash forecasting* e la riconciliazione automatica, il tempo dedicato ad attività operative è diminuito in media del 65% (con un intervallo compreso tra il 40% e l'85%), mentre il tempo disponibile per attività di analisi, pianificazione finanziaria e consulenza al management è aumentato in misura corrispondente.

²⁹ Teece, Pisano & Shuen, 1997

La quantificazione monetaria di questo beneficio richiede tuttavia molta cautela. Il risparmio di ore-uomo non si traduce automaticamente in una riduzione del costo del lavoro per l'impresa, in quanto la modalità prevalente di realizzazione del risparmio è il *redeployment* (ricollocaimento), ovvero la **riassegnazione degli FTE (Full Time Equivalent)**, ovvero l'unità di misura aziendale che parametrizza il volume di ore lavorate rispetto a un dipendente a tempo pieno) liberati dall'automazione verso attività a maggior valore aggiunto all'interno della medesima funzione³⁰. In questo scenario, il beneficio è reale ma intangibile, pur non appearing come voce di risparmio esplicita nel conto economico, si manifesta nell'incremento della qualità delle analisi prodotte dalla tesoreria. La monetizzazione diretta (ottenuta attraverso la riduzione effettiva dell'organico o il mancato rinnovo di posizioni vacanti turnover aziendale) è documentata in una quota minore di casi, stimabile intorno al 20-30% delle implementazioni³¹, e risulta più frequente nelle imprese con strutture sovradimensionate rispetto all'effettivo volume transazionale.

A conferma di queste dinamiche, il caso della **tesoreria globale di Microsoft** offre un riscontro concreto sull'impatto dell'automazione intelligente. L'implementazione di modelli predittivi basati sul machine learning e integrati nell'ecosistema ERP ha consentito un abbattimento fino al 90% delle attività manuali di reportistica di cassa. Questa evoluzione infrastrutturale ha generato un'accelerazione del 50% nei cicli previsionali, permettendo al team finanziario di reindirizzare le proprie risorse verso l'analisi strategica, con un conseguente incremento del 25% nell'efficienza del capitale circolante.

Riduzione degli Errori e Maggiore Accuratezza dei Processi

L'errore operativo in tesoreria non è una voce astratta di rischio, bensì un onere diretto e misurabile che si manifesta attraverso molteplici canali. Ad esempio, una differenza di riconciliazione non rilevata tempestivamente, compromette la qualità delle decisioni di finanziamento, creando un disallineamento tra la posizione di cassa contabile e quella effettiva. Parallelamente, un'anomalia nei pagamenti in uscita sfuggita ai controlli espone l'impresa a perdite finanziarie

³⁰ Prosci, 2023

³¹ Gartner, 2024

dirette ed a potenziali sanzioni normative. Inoltre, una previsione distorta da imprecisioni nell'inserimento dei dati induce a decisioni di approvvigionamento della liquidità subottimali, i cui costi occulti si propagano lungo l'intera catena della gestione finanziaria.

Per arginare tali inefficienze, i moderni sistemi di riconciliazione basati su algoritmi di machine learning operano attraverso meccanismi di *pattern matching* (riconoscimento di schemi) adattivi. Questa tecnologia consente di abbinare automaticamente le transazioni bancarie alle registrazioni contabili, superando le difficoltà legate a variazioni nei formati, negli importi o nelle descrizioni testuali. A differenza delle regole dei sistemi di prima generazione, i modelli ad apprendimento automatico assimilano progressivamente le eccezioni e i pattern irregolari tipici dell'operatività di ciascuna impresa, raggiungendo tassi di abbinamento automatico superiori al 90%³². Le transazioni residuali vengono segnalate e corredate da un profilo di rischio, orientando l'attenzione del cash manager esclusivamente verso i casi di maggiore rilevanza, abbattendo i tempi di analisi e innalzando la probabilità di intercettare anomalie significative.

La contrazione del rischio operativo connessa a questa forma di automazione assume una valenza quasi assicurativa, che la letteratura di enterprise risk management formalizza attraverso il concetto di **expected loss reduction** (riduzione della perdita attesa)³³. Nelle funzioni di tesoreria di medie dimensioni, la stima aggregata delle perdite evitate, comprensiva dei costi di correzione manuale, dei mancati recuperi su riconciliazioni incomplete e delle penali per ritardi nei pagamenti, si colloca in un intervallo compreso tra i 10.000 e i 25.000 euro annui³⁴. Tali valori registrano peraltro picchi più elevati all'interno di imprese caratterizzate da ingenti volumi transazionali o da esposizioni valutarie complesse.

Accelerazione del Time-to-Close e dei Cicli di Processo

Un beneficio Automational spesso sottovalutato nelle analisi di business case è

³² Citigroup, 2025.

³³ Nocco & Stulz, 2006

³⁴ Bain & Company, 2024

la riduzione delle tempistiche legate ai processi di tesoreria. La **riduzione del time-to-close** (ovvero il tempo necessario per completare la riconciliazione giornaliera, generare la posizione di cassa aggiornata e produrre la reportistica per il CFO) determina l'ampiezza della finestra decisionale a disposizione del management per intervenire sulla posizione di liquidità prima che le opportunità di mercato svaniscano. Il caso della **tesoreria globale di Spotify** quantifica con precisione la portata di questo vantaggio. L'integrazione di un'infrastruttura basata su **API bancarie e RPA** (Robotic Process Automation) ha consentito di automatizzare il 95% delle procedure di cash positioning, anticipando di diverse ore l'avvio della chiusura giornaliera dei conti su scala globale³⁵. Ottenere ore di visibilità aggiuntiva sulla liquidità globale non rappresenta un dettaglio marginale, bensì costituisce il limite tra l'ottimizzazione delle eccedenze nei mercati monetari e il mantenimento di un'ingente liquidità infruttifera. Parallelamente, l'impatto sull'efficienza del ciclo di chiusura mensile risulta altrettanto incisivo. L'analisi condotta dall'Association for Financial Professionals³⁶ evidenzia una riduzione mediana di quasi due giorni lavorativi nel ciclo di chiusura mensile per le organizzazioni dotate di strumenti IA avanzati. Si tratta di un recupero di efficienza i cui benefici si propagano lungo l'intero processo amministrativo, agevolando in modo diretto le attività della funzione di Financial Planning & Analysis.

2.2.3 Benefici Informational: Qualità Decisionale Superiore

La categoria *Informational* identifica la classe di benefici che si origina dal miglioramento qualitativo dell'informazione a supporto del processo decisionale. In tesoreria, questa dimensione è particolarmente critica poiché la qualità delle decisioni finanziarie dipende dalla precisione e dalla tempestività delle informazioni di base. Una previsione di cassa inaccurata o disponibile con ritardo non inficia solo l'efficienza operativa, ma deteriora la qualità delle decisioni strategiche con impatto diretto sul conto economico e sul profilo di rischio dell'impresa.

³⁵ Kyriba, 2023

³⁶ AFP, 2024

Accuratezza del Forecast e Impatto Manageriale

Il miglioramento dell'accuratezza previsionale rappresenta il beneficio *Informational* più quantificabile e quello maggiormente consolidato e validato dalla ricerca accademica. L'efficacia dell'IA si manifesta nella **contrazione strutturale del MAPE** (*Mean Absolute Percentage Error*), che passa dai livelli critici dell'era predigitale a valori compresi tra il 3% e il 9%.

Sia la letteratura manageriale che le evidenze applicative convergono sul punto secondo il quale l'impiego di reti neurali e algoritmi predittivi permette di superare i limiti strutturali dei tradizionali modelli lineari, determinando un incremento sostanziale nell'accuratezza del *forecast*. Sotto il profilo quantitativo, tale incremento di precisione determina una contrazione strutturale del MAPE. Come evidenziato da McKinsey & Company (2024), questo indicatore crolla dai livelli critici dell'era predigitale assestandosi in un *range* compreso tra il 3% e il 9%. Tuttavia, l'efficacia dell'intelligenza artificiale non si esaurisce nella semplice minimizzazione degli scostamenti percentuali, permettendo al *management* di operare con intervalli di confidenza nettamente più ristretti, consentendo di controllare la volatilità dei flussi di cassa con una capacità di anticipazione non raggiungibile attraverso i metodi statistici tradizionali.

Le implicazioni strategiche di questa maggiore accuratezza innescano una vera e propria reazione a catena che trasforma la gestione della tesoreria. L'effetto più immediato si osserva sull'ottimizzazione del **buffer** (cuscinetto) precauzionale di liquidità; infatti, operando con un margine di errore ridotto, l'impresa può minimizzare i fondi tenuti in garanzia. Come dimostrato dalla trasposizione finanziaria della teoria della gestione delle scorte, in cui la riserva di cassa funge da riserve precauzionale³⁷ una riduzione del 70% del MAPE autorizza una contrazione del *buffer* del 40-50% a parità di solvibilità. Questo meccanismo libera preziose risorse aziendali precedentemente immobilizzate e non remunerate.

La capacità di gestire il capitale interno in modo più efficiente si riflette sulle scelte di approvvigionamento esterno. La precisione previsionale incide infatti in misura determinante sul **timing** delle decisioni di **fundng** (finanziamento).

³⁷ Brealey, Myers & Allen, 2020,

Potendo contare su un *forecast* affidabile con un orizzonte di 7-14 giorni, il tesoriere acquisisce la facoltà di pianificare il ***draw-down*** (tiraggio) delle linee di credito nei momenti in cui i tassi di mercato risultano più vantaggiosi. Viene così neutralizzata la necessità di ricorrere al credito d'emergenza, ovvero quegli scenari in cui l'urgenza riduce al minimo il potere contrattuale dell'impresa. Poter dimostrare un ***track record*** di previsioni costantemente accurate costruisce un vero e proprio *asset* reputazionale agli occhi delle banche. Questa comprovata affidabilità, se condivisa con trasparenza e regolarità, si traduce nel riconoscimento di condizioni applicative nettamente più favorevoli sulle linee di credito *revolving*, culminando in un abbattimento strutturale del costo del debito a breve termine.

Visibilità Real-Time e Riduzione della Latenza Informativa

La latenza informativa rappresenta il limite strutturale fondamentale del paradigma di tesoreria predigitale. I sistemi AI di nuova generazione, alimentati da **API bancarie** in tempo reale conformi agli **standard Open Banking** (PSD2, ISO 20022), abbattano questa latenza portando la visibilità sulla posizione di cassa da un orizzonte di T-1/T-2 (dato del giorno precedente) a una disponibilità continua nel corso della giornata operativa.

Il valore strategico di questa tempestività non è uniforme lungo l'arco della giornata lavorativa, ma si concentra in quelle specifiche finestre temporali in cui le decisioni di allocazione della liquidità (dall'investimento delle eccedenze nei mercati monetari all'attivazione di linee *intraday*, fino alle operazioni di *cash pooling* intercompany) devono essere finalizzate prima della chiusura dei mercati finanziari. Come osservato da HSBC Global Banking (2025), la connettività API in tempo reale non rappresenta più un'opzione tecnologica, bensì il prerequisito infrastrutturale per qualsiasi sistema di AI predittiva dato che un modello che riceve dati con il ritardo di un giorno non può generare segnali decisionali azionabili nelle finestre di opportunità *intraday*.

Un riscontro quantitativo del valore della visibilità in tempo reale è offerto dall'esperienza del **gruppo farmaceutico Roche**. La centralizzazione della tesoreria, avvenuta tramite la creazione di un'*in-house bank*, ha permesso di consolidare la visibilità *intraday* per quasi 250 entità legali distribuite in oltre 50

Paesi (EuroFinance, 2021). Questa architettura ha consentito di abbattere i tempi di riconciliazione dei flussi bancari e di superare i colli di bottiglia fisiologici dei sistemi *legacy*, abilitando una gestione centralizzata volta a implementare sistematicamente strategie di *yield enhancement* (ottimizzazione dei rendimenti) sulle eccedenze

2.2.4 Benefici Transformational: Ridefinizione Organizzativa

I benefici *Transformational* rappresentano la dimensione più profonda, e al contempo la più complessa da quantificare attraverso le analisi di breve periodo per la creazione di valore generata dall'IA in tesoreria. Il loro effetto non si manifesta attraverso la sola riduzione di un costo, bensì tramite una modifica delle competenze, dei ruoli e delle capacità organizzative della funzione finanziaria. Si tratta di un'evoluzione che richiede tempo per dispiegarsi pienamente, tipicamente un orizzonte compreso tra i 12 e i 24 mesi dall'adozione del sistema, ma che genera un vantaggio competitivo caratterizzato da una durabilità nettamente superiore rispetto ai semplici benefici di efficienza.

Evoluzione del Ruolo del Cash Manager

La letteratura sul futuro del lavoro nelle funzioni finanziarie³⁸ identifica un pattern ricorrente nell'evoluzione del ruolo del cash manager a seguito dell'adozione di sistemi di intelligenza artificiale. Si osserva, in particolare, una riduzione del tempo dedicato ad attività di natura puramente esecutiva e operativa (quali la raccolta e normalizzazione dei dati, la produzione di report standardizzati e l'esecuzione manuale delle riconciliazioni) a totale **vantaggio di mansioni ad elevato contenuto analitico e relazionale**. L'analisi condotta da Deloitte (2024) su un campione di responsabili finanziari europei documenta tale transizione con precisione. Nelle organizzazioni che hanno integrato soluzioni AI di tesoreria raggiungendo un sufficiente livello di maturità digitale, l'incidenza delle mansioni operative sul totale del tempo lavorativo del cash manager è crollata dal 60-70% (tipico dell'era pre-digitale) a un marginale 20-30%. Il tempo così liberato viene riassorbito in attività ad alto valore aggiunto,

³⁸ Davenport & Ronanki, 2018; Accenture, 2023

come l'analisi degli scenari di liquidità, la consulenza strategica al CFO sulla struttura del funding a breve termine e la gestione proattiva delle relazioni con il sistema bancario.

McKinsey & Company (2024) evidenzia un'evoluzione nel grado di coinvolgimento della tesoreria all'interno dei processi decisionali strategici. La partecipazione della funzione ai comitati direttivi passa da una periodicità tradizionalmente trimestrale a un coinvolgimento sistematico su base settimanale o quindicinale. Questa profonda trasformazione genera implicazioni dirette non soltanto sul profilo di competenze richiesto al cash manager del futuro, ma anche sulle logiche di talent management dell'intera funzione. Al professionista moderno è infatti richiesto di integrare la solida conoscenza finanziaria tradizionale con competenze avanzate di **data literacy** (alfabetizzazione ai dati), affinando la capacità di interpretare criticamente gli output algoritmici e di tradurli in una comunicazione quantitativa efficace verso l'alta direzione. L'evoluzione verso ruoli a maggior contenuto analitico e strategico tende naturalmente ad attrarre profili altamente qualificati, generando **tassi di engagement** (coinvolgimento) e **retention** (trattenimento del personale) nettamente superiori.

Nuove Organizational Capabilities

Il concetto di ***organizational capability*** (capacità organizzativa), esplicitato nella *Resource-Based View*³⁹ e nella teoria delle *dynamic capabilities*⁴⁰, descrive quell'insieme di competenze difficilmente imitabili in grado di generare un vantaggio competitivo durevole. Applicando questo paradigma alla tesoreria, l'introduzione dell'intelligenza artificiale non si limita a ottimizzare i processi esistenti, ma innesca un vero e proprio mutamento strutturale. Il cambiamento più impattante si osserva nel passaggio da un approccio reattivo ad uno anticipatorio, sviluppando una reale ***predictive liquidity management capability*** (capacità di gestione predittiva della liquidità) nella quale l'impresa acquisisce la facoltà di rilevare i fabbisogni di cassa con intere settimane di anticipo. L'acquisizione di una simile capacità di anticipazione rafforza le dinamiche di

³⁹ Barney, 1991

⁴⁰ Teece, Pisano & Shuen, 1997

interazione con il sistema bancario, offrendo all'impresa l'opportunità di negoziare il *funding* in condizioni di stabilità strutturale e al riparo dalle pressioni imposte dai fabbisogni improvvisi.

Tuttavia, un simile ampliamento dell'orizzonte temporale non potrebbe sostenersi senza una profonda evoluzione interna nel modo in cui vengono prese le decisioni. L'affidamento sui modelli algoritmici necessita una solida ***data-driven decision culture*** (cultura decisionale guidata dai dati). Le scelte operative iniziano così a fondarsi su evidenze quantitative, scenari simulati e rigorosi intervalli di confidenza. Sebbene questo cambiamento culturale richieda delle tempistiche che variano dai due o tre anni per sedimentarsi, il suo impatto innalza la qualità dell'elaborazione informativa dell'intera struttura aziendale, generando ricadute estremamente positive per dipartimenti contigui come il *Financial Planning & Analysis* e le *Investor Relations*. L'esigenza stessa di mantenere efficiente questo nuovo ecosistema decisionale consolida un'ulteriore competenza distintiva. L'obbligo di **monitorare costantemente le performance** del modello predittivo, utilizzando dati sempre aggiornati e di ricalibrarne i parametri finanziari, orientando questo modello ad un miglioramento continuo. Si tratta di un assetto organizzativo fortemente adattivo che si traduce in ritorni tangibili, come evidenziato da un'analisi pubblicata sulla *MIT Sloan Management Review* (Ransbotham, Kiron & Prentice, 2016), nel quale viene affermato che le aziende capaci di interiorizzare questa attitudine iterativa registrano *performance* di lungo termine superiori del 12-18% in termini di ROE (*Return on Equity*) rispetto ai *competitor* meno evoluti.

2.2.5 Benefici Financial: Impatto Bottom-Line

I benefici *Financial* traducono i miglioramenti operativi, informativi e organizzativi discussi nelle sezioni precedenti in grandezze economiche direttamente leggibili nel bilancio d'esercizio. Vi sono due meccanismi di trasmissione, i quali risultano essere particolarmente rilevanti per le funzioni di tesoreria, che sono: la riduzione degli oneri finanziari netti e la liberazione di capitale circolante attraverso l'ottimizzazione del Capitale Circolante Netto.

Riduzione degli Oneri Finanziari

La maggiore accuratezza decisionale si traduce in un abbattimento diretto degli oneri finanziari di struttura. L'impatto sul conto economico non deriva unicamente da migliori tempistiche di accesso al credito, ma si concretizza in un'ottimizzazione quantitativa del *sizing* (dimensionamento) delle linee di credito attivate. In un contesto di previsione tradizionale, la direzione finanziaria è incentivata a richiedere l'apertura di fidi bancari sovradimensionati rispetto al fabbisogno atteso, utilizzandoli come forma di assicurazione contro l'incertezza. Tuttavia, questo margine di sicurezza genera un **costo esplicito**, dato dal pagamento di ingenti *commitment fees* (commissioni di mancato utilizzo) applicate dagli istituti di credito sulla quota accordata e lasciata inutilizzata. L'abbattimento strutturale del margine di errore garantito dai sistemi IA elimina la necessità di mantenere questa sovracapacità prudenziale. Come confermato da PwC (2024), la conseguente ottimizzazione degli affidamenti bancari consente di comprimere in misura drastica l'incidenza di tali commissioni, traducendosi in un beneficio economico netto e immediato a conto economico. A conferma della rilevanza di tale fenomeno, i dati raccolti attraverso le indagini dell'Association for Financial Professionals⁴¹ evidenziano come le implementazioni di successo portino a una contrazione strutturale degli oneri finanziari netti, con benefici medi che si attestano spesso in doppia cifra percentuale rispetto ai livelli pre-adozione.

Ottimizzazione del Capitale Circolante Netto (Working Capital Requirement)

L'impatto dell'intelligenza artificiale si manifesta sull'efficienza del ciclo di cassa, favorendo lo svincolo di risorse precedentemente assorbite dal Capitale Circolante Netto (CCN). Questo risultato si ottiene attraverso un'ottimizzazione delle principali grandezze del capitale circolante. L'integrazione di modelli di *machine learning* per l'analisi dei crediti commerciali abilita una **gestione proattiva delle attività di recupero**. Anticipando con precisione le probabilità di insolvenza o di ritardo nei pagamenti, le imprese riescono a imprimere una contrazione strutturale ai giorni medi di incasso (DSO) prima che l'inefficienza si materializzi. Le evidenze empiriche tracciate da The Hackett Group (2023)

⁴¹ AFP, 2024

confermano una riduzione mediana del DSO compresa tra i 4 e i 7 giorni per le organizzazioni dotate di funzionalità predittive. L'azione di ottimizzazione non si esaurisce tuttavia sul ciclo attivo, ma si estendono anche alla gestione del passivo. L'applicazione di algoritmi beneficia di *supervised learning* alla schedulazione dei pagamenti in uscita consente al sistema di valutare costantemente le opportunità di sconto per pagamento anticipato, soppesandole con il costo opportunità della liquidità disponibile. A chiusura dell'intero ciclo operativo, questa maggiore confidenza sui flussi di cassa si riflette positivamente anche sulla gestione logistica, infatti la direzione può operare con scorte più contenute (DIO), riducendo ulteriormente il capitale immobilizzato in magazzino.

L'effetto combinato di queste ottimizzazioni restituisce all'impresa un potenziale finanziario considerevole. Come quantificato da REL Consultancy (2022), il distacco in termini di CCN tra le organizzazioni *best-in-class* e la media del mercato si attesta a 6 punti percentuali dei ricavi, traducendosi, per un'azienda da 100 milioni di fatturato, in un potenziale recupero di capitale pari a 6 milioni di euro. Ai fini della valorizzazione contabile, questo beneficio si monetizza moltiplicando il volume di Capitale Circolante abbattuto per il costo medio ponderato del capitale (WACC). Una simile dinamica fa sì che una contrazione del CCN di 2 milioni di euro, a fronte di un WACC del 7%, si converta in un risparmio strutturale di 140.000 euro all'anno. Oltre a garantire questo risparmio strutturale, l'ottimizzazione del capitale circolante assicura all'impresa una **strategica generazione di cassa straordinaria**. Si tratta di liquidità definitivamente svincolata dal ciclo operativo, che dota la tesoreria delle risorse necessarie per accelerare la riduzione dell'indebitamento finanziario o per supportare iniziative a valore attuale netto positivo.

2.3 Il Ritorno sull'Investimento: Evidenze Empiriche e Determinanti del Successo

L'implementazione dell'intelligenza artificiale in tesoreria genera ritorni economici tangibili, come il recupero di liquidità grazie all'ottimizzazione del Capitale Circolante Netto e la riduzione degli oneri finanziari. La direzione

finanziaria, per poter deliberare l'investimento, deve prima aggregare questi flussi positivi e confrontarli con i costi di adozione del sistema, sintetizzando tali evidenze in un indicatore di rendimento unitario, ovvero il **ROI (Return on Investment)**. Tuttavia, non bisogna limitare la valutazione del progetto informatico solamente a questo indicatore, altrimenti si rischia di prendere decisioni errate. Nel caso specifico dell'IA, infatti, la misurazione del ritorno economico deve infatti confrontarsi con una struttura di benefici eterogenea (comprendente anche vantaggi strategici non immediatamente monetizzabili) e con un orizzonte temporale che supera i rigidi confini del *budgeting* annuale.

2.3.1 Metodologia Sintesi ROI

La letteratura sull'IT Business Value ha elaborato nel corso dei decenni diversi framework per riconciliare la natura multidimensionale dei ritorni tecnologici con la necessità di una valutazione economica unitaria. L'approccio più rigoroso discende dai contributi di Brynjolfsson e Hitt (1996) sul **paradosso della produttività informatica**. Gli autori distinguono tra **benefici di primo ordine**, direttamente monetizzabili attraverso la contrazione dei costi operativi, e **benefici di secondo ordine**, la cui valorizzazione richiede un passaggio intermedio attraverso variabili organizzative e decisionali.

Per le soluzioni AI applicate alla tesoreria, tale distinzione assume una valenza pratica immediata. I **benefici *Automational* e *Financial*** appartengono chiaramente alla prima categoria. Il risparmio sulle *commitment fees* (commissioni di mancato utilizzo) o la riduzione degli oneri finanziari legata allo svincolo del CCN sono grandezze direttamente osservabili nel conto economico. I **benefici *Informational* e *Transformational*** richiedono invece metodologie di valorizzazione indiretta. A questo proposito, la ricerca di Davern e Kauffman (2000) introduce l'essenziale distinzione tra ***Potential Value* e *Realized Value***. La differenza tra queste due misure dipende dalla capacità dell'organizzazione di convertire le potenzialità tecniche in vantaggi operativi misurabili. Ad esempio, un sistema di *cash forecasting* capace di ridurre il MAPE al 5% configura come un *potential value* elevato. La sua effettiva conversione in risparmio monetario resta però dipendente dalla prontezza del *management*

nell'agire tempestivamente, trasformando l'informazione in decisioni strategiche mirate. Proprio per superare i limiti di una valutazione contabile e catturare questa dinamica di conversione del valore, la prassi metodologica integra l'approccio del **Total Economic Impact** (TEI) introdotto da Forrester Research. Questo modello non si limita a una rilevazione statica dei flussi, ma scompone il rendimento dell'investimento in una struttura capace di isolare quattro componenti fondamentali, che sono: i benefici diretti quantificabili, la flessibilità opzionale, i costi che la soluzione permette di sostituire e l'abbattimento dei rischi operativi, quest'ultimo espresso tipicamente come contrazione del *Value at Risk* (VaR). Questa impostazione risulta particolarmente adatta al contesto della tesoreria predittiva poiché è in grado di valorizzare le cosiddette *real options* acquistate implicitamente dall'impresa con l'adozione del sistema. Questo genera il vantaggio di poter estendere l'operatività verso nuove entità legali e mercati valutari abbattendo i costi marginali, nonché nell'opportunità di innestare moduli avanzati di copertura dinamica dei rischi o agenti conversazionali su un'infrastruttura tecnologica già consolidata.

L'analisi di questa flessibilità introduce tuttavia un ulteriore elemento di complessità legato alla corretta delimitazione dell'orizzonte temporale. Se da un lato la transizione verso il modello SaaS ha reso i flussi di costo e di beneficio sostanzialmente simmetrici nel tempo, contrapponendo canoni ricorrenti a risparmi altrettanto costanti, essa ha introdotto una componente di *option value* legata all'aggiornamento tecnologico continuo che i modelli classici di *Capital Budgeting*, basati su flussi di cassa deterministici, faticano a catturare. Come dimostrato da Copeland e Antikarov (2001), il valore di queste opzioni reali di espansione o di adattamento può rappresentare fino al 20% del **Valore Attuale Netto** (NPV). Ne consegue che la capacità di evoluzione del sistema costituisce una componente non trascurabile nelle decisioni di investimento, la cui esclusione porterebbe a una sottostima del reale valore generato dall'intelligenza artificiale per l'organizzazione.

2.3.2 Payback Period e Net Present Value

Il passaggio dalla teoria alla misurazione operativa si concretizza attraverso

l'applicazione delle metriche classiche di *Capital Budgeting*. Il **Payback Period** (periodo di rientro dell'investimento) misura l'intervallo temporale necessario affinché i flussi di cassa incrementali generati dall'investimento eguagliano l'esborso iniziale netto. Nella sua forma semplificata, esso corrisponde al rapporto tra il CAPEX iniziale (o, nel modello SaaS, il costo di configurazione e implementazione) e il flusso di cassa annuo incrementale atteso nell'esercizio di regime.

La transizione dal paradigma *on-premise* al modello *Software as a Service* ha determinato una contrazione del periodo di recupero, riducendo il rischio finanziario dell'operazione. Nel paradigma tradizionale, l'esborso iniziale, tipicamente categorizzato come *CAPEX* poiché comprensivo di licenze perpetue, infrastruttura hardware e onerosi costi di installazione, imponeva orizzonti di rientro che le analisi di Gartner (2023) collocano mediamente tra i 30 e i 42 mesi. L'adozione del modello SaaS abbatte questa barriera temporale. Isolando l'esborso iniziale alle sole attività di configurazione e permettendo ai risparmi di materializzarsi già nei primi trimestri operativi, il modello SaaS accelera in modo decisivo il recupero dei capitali. A conferma di questa dinamica, le rilevazioni condotte da Forrester Research (2023) su un campione di implementazioni in tesoreria evidenziano un *Payback Period* mediano di soli 15-18 mesi, orizzonte che si restringe ulteriormente a 9-12 mesi per le organizzazioni caratterizzate da un'elevata maturità digitale. Confrontando tali metriche con i classici progetti di trasformazione informatica aziendale, che secondo McKinsey & Company (2024) richiedono solitamente tra i 24 e i 36 mesi per raggiungere il pareggio, emerge chiaramente come l'intelligenza artificiale applicata al *cash management* presenti un profilo di rischio finanziario nettamente più contenuto.

Il **Net Present Value** (NPV, o Valore Attuale Netto) incorpora il valore temporale del denaro attraverso l'attualizzazione dei flussi di cassa futuri al tasso di rendimento richiesto dall'impresa. La formula del NPV è la seguente:

$$NPV = -I_0 + \sum_{t=1}^T \frac{CF_t}{(1+WACC)^t}$$

In questa formula I_0 rappresenta l'investimento iniziale netto (CAPEX più eventuale costo di transizione), CF_t il flusso di cassa incrementale al periodo t (benefici al netto dei canoni SaaS ricorrenti e dei costi di manutenzione), e il $WACC$ aziendale funge da tasso di attualizzazione, incorporando sia il costo del capitale proprio che quello del debito ponderati per la struttura finanziaria dell'impresa.

Sul piano applicativo, la corretta determinazione dei flussi CF_t impone un rigoroso controllo temporale delle componenti di valore. Diventa necessario non confondere lo svincolo di liquidità dal Capitale Circolante Netto, che rappresenta un **impatto straordinario di stock** limitato alla fase di ottimizzazione iniziale, con il conseguente abbattimento degli oneri finanziari, che costituisce invece un **beneficio strutturalmente ricorrente**. L'errata classificazione di queste grandezze all'interno del *business case* (ad esempio imputando l'intero capitale svincolato come entrata annua costante) rappresenta uno degli errori valutativi più comuni, capace di generare una sovrastima sistematica del Valore Attuale Netto.

Tuttavia, pur depurando i modelli da simili distorsioni, le evidenze empiriche confermano l'attrattività economica di tali progetti. "Le evidenze empiriche raccolte nei report di McKinsey & Company (2024) sulle adozioni di piattaforme AI nelle funzioni finanziarie riportano NPV mediani ampiamente positivi, dimostrando la scalabilità di questi investimenti. L'elevata varianza nei risultati dimostra come la creazione di valore non costituisca una proprietà intrinseca del software, imponendo un'analisi rigorosa delle variabili organizzative e strategiche che ne condizionano l'effettiva realizzazione.

2.3.3 Determinanti del ROI: Analisi fattori

L'elevata varianza riscontrata nei rendimenti suggerisce che la creazione di valore non sia una prerogativa esclusiva della tecnologia in sé. Tale evidenza impone un'indagine approfondita sulle determinanti organizzative e sulle scelte strategiche che ne comportano benefici monetari. Questa prospettiva trova il proprio fondamento teorico nel filone di **ricerca sulle complementarità**

organizzative inaugurato da Milgrom e Roberts (1990), secondo cui il rendimento degli investimenti tecnologici dipende dalla sua interazione con la struttura aziendale e i processi decisionali esistenti. La variabile con il maggiore potere esplicativo sulla varianza del ROI è la **maturità della Data Architecture preesistente**. I sistemi di intelligenza artificiale per la tesoreria funzionano come amplificatori dell'informazione. Essi sono in grado di estrarre segnali predittivi di alta qualità se le informazioni su cui operano sono coerenti ed attendibili. Lo studio comparativo di Lavallo et al. (2011) rileva che le organizzazioni con una maturità analitica elevata (classificate come *Analytically Sophisticated* nella tassonomia dell'analisi) ottengono ritorni dagli investimenti in tecnologie predittive superiori del 60% rispetto alle organizzazioni nella categoria inferiore, a parità di investimento tecnologico. Nell'ottica della tesoreria, sta a significare che un'impresa che opera su un ERP integrato e ben governato, con serie storiche bancarie pluriennali e processi di riconciliazione già digitalizzati, si trova in una posizione di partenza strutturalmente avvantaggiata rispetto a un'organizzazione che deve affrontare la fase di *data cleansing* come attività preliminare all'implementazione.

Tuttavia, la disponibilità di dati di qualità non è sufficiente se non supportata da un solido **allineamento strategico tra la funzione finanziaria e il comparto IT** (*Business-IT Alignment*). La ricerca di Henderson e Venkatraman (1993), formalizzata nel *Strategic Alignment Model*, dimostra che il divario tra la strategia tecnologica e quella di business è la principale causa di non realizzazione del valore potenziale sugli investimenti IT. In tesoreria, questo disallineamento si traduce spesso in un governo inefficiente delle API bancarie o in KPI non condivisi, che impediscono il raggiungimento degli obiettivi di rendimento previsti dal *business case* entro i tempi stabiliti. Pertanto, le organizzazioni che formalizzano un piano di *IT governance* integrato, hanno una probabilità di successo del progetto superiore⁴².

A queste variabili, si affianca la dimensione del fattore umano, definibile come **Organizational Readiness**. Secondo la ricerca di Orlikowski (2000), la tecnologia non produce cambiamento in modo autonomo, ma agisce come

⁴² Weill & Ross, 2004

abilitatore di pratiche che gli individui devono scegliere di adottare. Questa dinamica assume la forma specifica della tensione tra la fiducia algoritmica e il giudizio professionale. Il cash manager che non si fida dell'output previsionale del modello, o che lo utilizza come semplice elemento di conferma del proprio giudizio, senza modificare i propri processi decisionali, annulla di fatto i benefici Informational e Financial attesi. Il grado di preparazione dell'organizzazione (*Readiness*) non è un dato qualitativo per affermarsi come una determinante economica misurabile. Gli studi condotti da Prosci (2023) evidenziano infatti come, a parità di infrastruttura tecnologica, le iniziative penalizzate da un deficit nella propensione al cambiamento subiscono una contrazione media del ROI pari al 40% rispetto ai progetti implementati in contesti aziendali dotati di un'elevata recettività.

L'efficacia economica dell'investimento è influenzata inoltre, da una determinante di natura strutturale, ovvero la **scala operativa** e il **volume transazionale dell'organizzazione**. Tale fattore agisce attraverso un classico meccanismo di economie di scala applicato all'investimento fisso tecnologico. I costi di implementazione e i canoni *SaaS* di base presentano una struttura prevalentemente fissa, mentre i benefici economici crescono in modo proporzionale al numero di transazioni processate, alle entità legali consolidate e ai conti monitorati, il rendimento tende a espandersi naturalmente all'aumentare della dimensione aziendale. Non si tratta di una superiorità tecnica, bensì della capacità dell'impresa di diluire i costi di adozione su un perimetro operativo più vasto. Come evidenziato dalle indagini di mercato di PwC (2024), l'efficacia economica dell'investimento mostra un effetto soglia netto nelle realtà che processano alti volumi transazionali (es. oltre 50.000 pagamenti annui), evidenziando una forte correlazione tra scala operativa e ROI. Di conseguenza, per le organizzazioni che non raggiungono una massa critica di transazioni, l'incidenza dei costi fissi e della complessità implementativa può rendere preferibile un approccio incrementale, focalizzato su strumenti di automazione standard o configurazioni tecnologiche più agili e proporzionate al reale volume dei flussi gestiti.

In ultima analisi, la convergenza di queste quattro determinanti (la maturità della

Data Architecture, l'allineamento tra *Business* e IT, la *Readiness* organizzativa e la scala operativa) dimostra che il rendimento di un sistema AI per la tesoreria non è un dato predeterminato dalla qualità del software, né una variabile esclusivamente dipendente dalle caratteristiche dell'acquirente. Il ROI emerge, al contrario, dalla costante interazione tra la potenza algoritmica dello strumento e la capacità dell'organizzazione di predisporre le condizioni strutturali necessarie alla sua valorizzazione. Questa prospettiva sposta il baricentro della decisione di investimento. Infatti, il CFO non è chiamato a scegliere semplicemente tra diverse piattaforme tecnologiche, ma a deliberare su un processo di trasformazione organizzativa i cui fattori critici di successo richiedono di essere pianificati e governati con la medesima disciplina riservata alle metriche finanziarie.

2.4 Framework Decisionale per il CFO: Valutare l'Investimento in AI

Se le determinanti del ROI analizzate in precedenza spostano il fulcro della valutazione dalla componente tecnologica alla capacità di assorbimento dell'organizzazione, emerge una necessità di *governance* che impone il superamento delle logiche di selezione basate esclusivamente su metriche di redditività finanziaria. La decisione sull'utilizzo dell'intelligenza artificiale in tesoreria non può esaurirsi nella sola analisi dei flussi di cassa attualizzati, poiché la natura stessa della tecnologia impone al *Chief Financial Officer* di agire come promotore strategico della trasformazione digitale. Di conseguenza, la decisione finale scaturisce da un giudizio integrato che deve necessariamente bilanciare la metrica quantitativa con una valutazione qualitativa dei rischi e una visione prospettica degli assetti competitivi dell'impresa.

2.4.1 L'Evoluzione del Mandato del CFO

La letteratura sulla *IT Governance* ha documentato nel corso degli ultimi due decenni una progressiva trasformazione del ruolo della direzione finanziaria nei processi di adozione tecnologica. Il contributo fondamentale di Weill e Ross

(2004) nel loro studio su 256 imprese internazionali dimostra che nelle organizzazioni con le migliori *performance* di lungo periodo, il CFO non si limita a controllare solamente i costi, ma governa i criteri di allocazione del capitale e l'indirizzo strategico degli asset digitali. Questa evoluzione ha assunto una particolare rilevanza con la diffusione delle piattaforme SaaS e dei sistemi basati su intelligenza artificiale. A differenza dei precedenti investimenti in ERP, le soluzioni AI per la tesoreria introducono dipendenze contrattuali di lungo periodo, rischi di conformità normativa ed implicazioni sul capitale umano che trascendono la semplice logica della gestione degli acquisti tecnologici. Come osservato da Bharadwaj, El Sawy, Pavlou e Venkatraman (2013) sulle *digital business strategies*, le imprese che registrano i maggiori ritorni dagli investimenti digitali sono quelle in cui il CFO esercita una supervisione attiva sulla trasformazione, traducendo la strategia finanziaria in vincoli e obiettivi misurabili per i progetti tecnologici. La responsabilità di questo compito supera la tradizionale funzione di controllo contabile, bensì deve valutare che vi sia coerenza strategica degli asset digitali rispetto alla traiettoria d'impresa.

2.4.2 Valutazione del Rischio: Oltre il NPV Positivo

La presenza di un Net Present Value (NPV) positivo e un *Payback Period* ristretto costituiscono condizioni necessarie ma non sufficienti per la delibera favorevole. Il processo decisionale del CFO deve incorporare una valutazione strutturata dei rischi avversi che la sola analisi dei flussi di cassa attesi non è in grado di catturare.

Una delle criticità più insidiose è rappresentata dal ***vendor lock-in***, fenomeno particolarmente accentuato nelle architetture SaaS. A differenza degli investimenti *on-premise*, nei quali l'impresa mantiene la proprietà del codice e dei dati, l'adozione di una piattaforma in abbonamento determina una progressiva migrazione dei processi critici verso l'infrastruttura del fornitore. Questa dipendenza aumenta proporzionalmente al grado di integrazione, il quale si può notare dalla connessione con i sistemi ERP, le API bancarie e l'addestramento di modelli su dati storici, che rendono elevate le barriere all'uscita. Le analisi di settore condotte da società come Forrester Research

(2023) documentano come il costo implicito di *switching* (cambio di fornitore) nelle piattaforme SaaS aziendali possa raggiungere un'incidenza rilevante sul TCO triennale, vanificando la flessibilità teoricamente garantita dal cloud. Per il CFO, questa valutazione si traduce nella necessità di negoziare contrattualmente clausole di *data portability* (portabilità dei dati), di definire *escrow* (depositi fiduciari) del codice sorgente e di verificare la solidità finanziaria del fornitore prima della firma.

la direzione finanziaria deve presidiare la **continuità operativa** durante la fase di transizione tecnologica. Il periodo di *parallel run*, ovvero la sovrapposizione temporanea tra i processi *legacy* e la nuova piattaforma, costituisce il momento di massima vulnerabilità. Durante questa fase, un'interruzione del sistema, oltre a generare costi di ripristino, rischia compromettere la visibilità sulla posizione di cassa in momenti critici per il ciclo finanziario dell'impresa. Il framework di valutazione del rischio operativo proposto da Soprano, Crielaard, Paci e Lannoo (2009) suggerisce di quantificare tale esposizione attraverso la stima del *Maximum Probable Loss* (MPL), ovvero il massimo impatto economico atteso in uno scenario di interruzione prolungata dei sistemi durante la migrazione.

A completare il quadro valutativo intervengono i vincoli di **conformità normativa e di data governance**. L'entrata in vigore dell'AI Act europeo (2024), classifica i sistemi di intelligenza artificiale utilizzati per la valutazione del rischio di credito e la gestione dei flussi finanziari come applicazioni ad alto rischio, imponendo obblighi di documentazione tecnica, tracciabilità delle decisioni automatizzate e supervisione umana sui risultati più critici. A questo si aggiunge la questione della *data sovereignty* (sovranità dei dati). Per le imprese operanti in giurisdizioni europee, il Regolamento GDPR impone che i dati finanziari dei clienti non vengano trasferiti a infrastrutture *cloud* localizzate fuori dai confini dell'Unione senza adeguate garanzie contrattuali. Il mancato rispetto di tali vincoli espone l'impresa non solo a sanzioni pecuniarie, ma a un rischio reputazionale verso le proprie controparti bancarie. In tale scenario, l'adozione di protocolli di *Explainable AI* (XAI) risponde alla necessità migliorare la trasparenza dei modelli neurali avanzati. Le autorità di vigilanza finanziaria richiedono appunto che le decisioni automatizzate possano essere spiegate e

motivate. Come documentato da Arrieta, Díaz-Rodríguez, Del Ser, Bennetot e García (2020), la capacità di interpretare i fattori che guidano le previsioni del modello non è solo un requisito normativo, ma un elemento che condiziona il grado di adozione interna dello strumento da parte dei cash manager.

2.4.3 Il Dilemma Sourcing: *Build* vs. *Buy*

Oltre alla mitigazione dei profili di rischio, il CFO è chiamato a definire la modalità di approvvigionamento della soluzione. La scelta tra lo **sviluppo interno (*build*)** e l'**acquisizione da un fornitore esterno (*buy*)** risponde a criteri che superano la semplice comparazione dei costi diretti, ma configura come una scelta strategica di posizionamento aziendale.

Lo sviluppo interno preserva la proprietà intellettuale dei modelli e delle architetture di dati, permettendo all'impresa di costruire una competenza distintiva difficilmente replicabile dai competitor. Barney (1991), nell'ambito della *Resource-Based View*, identifica proprio in questa unicità una delle condizioni per il vantaggio competitivo sostenibile. Per le imprese con ingenti volumi transazionali e strutture di tesoreria complesse (tipicamente le grandi multinazionali), l'investimento nello sviluppo di modelli proprietari può essere economicamente giustificato dall'estrema specificità delle dinamiche di cassa che solo i dati interni sono in grado di catturare. Ciononostante, la strategia *build* presenta ostacoli rilevanti. Richiede la formazione di competenze che risultano distanti alla funzione finanziaria, comporta tempi di sviluppo più lunghi rispetto al *time-to-market* garantito da un fornitore specializzato, ed espone l'impresa al rischio di obsolescenza tecnologica qualora il mercato evolva più rapidamente delle capacità interne.

La scelta *buy*, al contrario, comprime i tempi di implementazione e delega al fornitore l'onere del mantenimento e aggiornamento degli algoritmi, liberando risorse interne per attività a maggior valore strategico. In coerenza con il paradigma delle *dynamic capabilities* (capacità dinamiche) teorizzato da Teece (2018) afferma che nelle industrie caratterizzate da rapida innovazione tecnologica, la capacità di integrare le risorse esterne, piuttosto che svilupparle interamente in proprio, rappresenta una competenza organizzativa di ordine

superiore. La scelta ottimale per la maggioranza delle imprese di media dimensione si colloca in una struttura ibrida, andando ad acquisire una piattaforma SaaS come nucleo operativo, integrata con componenti di *customization* sviluppate internamente per preservare la specificità dei processi critici.

Il Multi-Criteria Business Case come Decisione Finale

Il momento deliberativo impone al CFO di ricondurre la sintesi delle metriche di redditività, l'esposizione al rischio e le logiche di *sourcing* all'interno di un *business case* integrato da sottoporre al Consiglio di Amministrazione. Questo documento non è la semplice sommatoria di analisi indipendenti, bensì una struttura argomentativa integrata che coniuga le dimensioni quantitative con quelle strategiche attraverso una logica di **portafoglio delle opzioni reali**⁴³. Applicando questo framework al contesto delle decisioni IT, come suggerito da Fichman, Keil e Tiwana (2005), la valutazione deve incorporare le opportunità strategiche latenti a bilanciamento dei profili di rischio. L'investimento in IA non si esaurisce infatti nella stima dei flussi di cassa diretti, ma genera opzioni implicite di crescita. La possibilità di scalare l'operatività o di integrare agilmente future innovazioni tecnologiche conferisce all'infrastruttura un *option value* che giustifica l'allocatione di capitale anche in presenza di un *payback* inizialmente incerto, qualificando l'approvazione del progetto come una vera e propria decisione di posizionamento.

Nel tradurre le diverse variabili analizzate in un unico documento decisionale, il **multi-criteria business case** abbandona la rigidità del singolo indicatore per far dialogare dimensioni profondamente interconnesse. La base quantitativa, legata al **rendimento finanziario atteso** (attraverso i valori di NPV, ROI e Payback Period), viene infatti calcolata in base al **profilo di rischio** dell'iniziativa, testato mediante analisi di sensitività e scenari di stress. Il passaggio cruciale risiede tuttavia nell'integrazione dello **Strategic Fit** (allineamento strategico) con le priorità aziendali di medio periodo. Richiamando il modello di *Strategic Alignment* di Henderson e Venkatraman (1993), la valutazione impone di misurare quanto l'investimento tecnologico sia in grado di rafforzare le

⁴³ Dixit e Pindyck, 1994

competenze distintive dell'organizzazione, accelerando l'esecuzione della strategia di *business*. Poiché l'equilibrio tra redditività, rischio e coerenza strategica varia a seconda della propensione al rischio dell'azienda, della sua solidità competitiva e dell'urgenza percepita verso la trasformazione digitale, l'atto decisionale cessa di essere un passaggio puramente tecnico. L'approvazione del CFO si configura, a tutti gli effetti, come una complessa scelta di governo, espressione diretta della visione del vertice sull'identità competitiva che l'impresa intende costruire nel medio periodo.

CAPITOLO 3 - ANALISI COMPARATA DEI MODELLI: PRE-AI VS POST-AI

3.1 Il Cash Forecasting Prima dell'IA: Metodologie Tradizionali

Sul piano manageriale, McKinsey (2023)⁴⁴ rileva che il cash forecasting è considerato il processo finanziario meno efficiente tanto nelle piccole quanto nelle grandi organizzazioni, con casi in cui la raccolta e compilazione dei dati di previsione richiede più di una settimana. Il PwC Global Treasury Survey 2025 conferma questa tensione: una quota significativa delle organizzazioni, il 38% per le aziende con ricavi superiori a \$10 miliardi, il 52% per la fascia \$1–10 miliardi, raccoglie e consolida ancora manualmente i dati di previsione, con livelli di soddisfazione medi pari a 2,9 su 5, e identifica nella scarsa qualità dei dati (76%) e nella mancanza di strumenti adeguati (53%) i principali ostacoli a un forecasting accurato.⁴⁵

Quest'ultimo report delinea chiaramente contesto si colloca la necessità, sempre più impellente, per le aziende moderne di accedere a nuovi strumenti di analisi dati, che riescano sia a gestire il dato di bassa qualità, che a semplificare il processo di analisi, automatizzandolo fin dalla raccolta e la pulizia dei dati e

⁴⁵ PwC, 2025

garantendo al contempo stime robuste. In quest'ottica, l'introduzione nell'ambito del cash management delle nuove tecnologie di intelligenza artificiale, rappresenta il breakthrough necessario a soddisfare le esigenze sopra descritte. Ma per comprendere quali siano gli attuali limiti infrastrutturali dei processi di stima dei flussi di cassa, ed apprezzare in modo critico la discontinuità introdotta dall'AI, comprendendo in che modo questa possa affiancare tecnologie/modelli e processi già presenti, è necessario soffermarsi sull'evoluzione delle tecniche di stima dei flussi di cassa.

Prima dell'affermarsi delle tecniche di intelligenza artificiale, la previsione dei flussi di cassa in ambito aziendale si è sviluppata attorno a due pilastri complementari: gli approcci statistici classici e il giudizio esperto del treasury manager. Questi due elementi non hanno mai operato in modo del tutto separato: nella pratica, i modelli quantitativi fornivano una base strutturata che il cash manager interpretava, integrava e correggeva alla luce di informazioni non codificabili in serie storiche (come ad esempio scadenze contrattuali attese, variazioni di budget o segnali di mercato).

3.1.1 Approcci statistici classici

Gli approcci statistici classici al cash forecasting si fondano sull'assunto che le dinamiche future dei flussi di cassa possano essere inferite a partire da regolarità osservabili nei dati storici. In tale prospettiva, i metodi basati su medie e trend, sviluppati durante la metà del XX secolo, rappresentano le tecniche più elementari e diffuse, costituendo spesso il punto di partenza nei sistemi di previsione aziendale e treasury management. Nonostante oggi si utilizzino metodi più sofisticati per la previsione di serie storiche, gli approcci classici rimangono comunque utili in termini di benchmarking dei modelli più moderni.

Medie mobili (Moving Average)

Il metodo delle medie mobili (Moving Average, MA) si basa sul principio di smoothing temporale, ossia sulla stima del valore futuro come media dei valori osservati più recenti della serie storica. Formalmente, la previsione al tempo $t+1$ è ottenuta attraverso il calcolo della media aritmetica degli ultimi n valori osservati.

La letteratura distingue diverse varianti:

- **Media mobile semplice (SMA):** assegna uguale peso a tutte le osservazioni;
- **Media mobile ponderata (WMA):** introduce pesi differenziati;
- **Media cumulativa:** aggiorna progressivamente la media includendo tutta la storia.

Questi modelli sono particolarmente semplici, ed adatti a serie senza trend o stagionalità marcata. Tali modelli rimangono ancora oggi rilevanti, nonostante la presenza di modelli più sofisticati. Ad esempio, la competizione M1⁴⁶ mostrò come i modelli semplici sono spesso accurati quanto, o più dei modelli complessi (es. Box-Jenkins), soprattutto con dati rumorosi. Da questo risultato, gli autori notano come non esista un metodo universalmente migliore: le performance dipendono dal tipo di dati e dall'orizzonte di previsione. Ciò rende difficile giustificare la complessità aggiuntiva in assenza di chiare evidenze di miglioramento.

Tra i risultati della competizione sopra citata, si osserva anche che la combinazione di più modelli migliora sistematicamente l'accuratezza rispetto a all'uso del singolo. In questo senso, i modelli a medie mobili rimangono. Inoltre è importante notare come questi modelli vengano utilizzati come *benchmark* standard nella valutazione dei modelli previsionali⁴⁷. La loro utilità in ambito di cash management risiede proprio in questo: offrire una baseline robusta e computazionalmente accessibile per la stima dei flussi ricorrenti.

Come citato in precedenza, i modelli a medie mobili presentano limiti rilevanti come l'incapacità di modellare esplicitamente trend e stagionalità e la forte dipendenza dalla finestra di n osservazioni scelta. In ambito di cash management aziendale, questi limiti si manifestano in modo particolarmente acuto: i flussi di cassa operativi sono soggetti a stagionalità, effetti di fine mese, variazioni legate al ciclo del capitale circolante e shock esogeni (cambi regolamentari, ritardi nei pagamenti clienti) che una media mobile semplice

⁴⁶ Makridakis et al., 1982

⁴⁷ Hyndman & Athanasopoulos, 2021

non è in grado di anticipare. Ciò rende tali metodi adatti a contesti operativi elementari, ma strutturalmente inadeguati in presenza di dinamiche finanziarie complesse.

Exponential Smoothing e modelli di trend

Per superare i limiti delle medie mobili, la letteratura ha sviluppato metodi basati su pesi decrescenti nel tempo, noti come *exponential smoothing*. A differenza delle medie mobili, questi modelli attribuiscono maggiore importanza alle osservazioni più recenti, implementando un meccanismo adattivo che migliora la reattività del modello. Tra i modelli più rilevanti, ricordiamo:

- il **simple exponential smoothing** (Brown) è adatto a serie senza trend⁴⁸
- il **modello di Holt** (*linear trend*) estende l'approccio introducendo una componente di trend esplicita.⁴⁹

Il modello di Holt, in particolare, è un metodo di previsione che estende lo smoothing esponenziale semplice introducendo esplicitamente una componente di trend. In pratica, il modello aggiorna nel tempo due elementi: il livello della serie e il suo trend, utilizzando due parametri di smoothing (α per il livello e β per il trend), permettendo così di adattarsi a serie che presentano una crescita o una decrescita sistematica. In ambito di tesoreria, questi metodi trovano applicazione nella previsione di incassi ricorrenti con andamento relativamente stabile, come i flussi legati a contratti di fornitura a lungo termine o alle riscossioni di crediti commerciali, dove la struttura autoregressive dell'*exponential smoothing* consente di cogliere l'inerzia dei flussi senza richiedere una parametrizzazione elaborata.

Il modello presenta alcune limitazioni importanti. In primo luogo, assume che il trend sia lineare e stabile nel tempo, il che può portare a errori quando la dinamica della serie cambia rapidamente. Inoltre, è sensibile alla scelta dei parametri e tende a produrre sovrastime nel lungo periodo, soprattutto quando il trend viene proiettato troppo avanti senza correzioni.

Tra gli anni 50' e gli anni 70' si assiste tanto alla diffusione di estensioni dei

⁴⁸ Brown, R. G. (1959)

⁴⁹ Holt, C. C. (1957)

modelli precedenti (si pensi al modello di Holt-Winters⁵⁰), quanto allo sviluppo di nuovi modelli. Negli anni '60 emergono i modelli di decomposizione classica, in cui la serie viene scomposta in trend, stagionalità e componente irregolare, spesso trattati separatamente ma sempre in un quadro ancora relativamente deterministico. In parallelo si sviluppano i primi modelli autoregressivi (AR) e a media mobile (MA), che introducono una visione pienamente stocastica della serie.

Questi ultimi danno l'abbrivio alla formalizzazione dei modelli appartenenti alla famiglia ARIMA (*AutoRegressive Integrated Moving Average*) negli anni '70'. Rispetto agli approcci precedenti, questi introducono una rappresentazione esplicita della struttura di dipendenza temporale della serie, modellando i flussi di cassa futuri come funzione lineare dei propri valori passati e dei residui laggiati. In ambito di cash management, ciò consente di catturare pattern autocorrelativi ricorrenti, come la persistenza degli incassi legata ai termini di pagamento o la regolarità dei flussi in uscita associata ai cicli di approvvigionamento, che i metodi basati su medie non riescono a rappresentare in modo strutturato.

Modelli ARIMA (AutoRegressive Integrated Moving Average)

I modelli ARIMA rappresentano, ancora oggi, uno dei riferimenti metodologici fondamentali nel forecasting delle serie temporali. Introdotti da Box e Jenkins (1970) con la pubblicazione di *Time Series Analysis: Forecasting and Control*, i modelli ARIMA, nella notazione standard ARIMA(p,d,q), combinano una componente autoregressiva (AR), che modella la dipendenza lineare dai valori passati della serie, una componente di integrazione (I), che rende stazionaria⁵¹ la serie tramite differenziazione, e una componente a media mobile (MA), che cattura la struttura di dipendenza dei residui. La metodologia Box-Jenkins fornisce un framework iterativo strutturato in tre fasi: identificazione del modello, stima dei parametri e verifica diagnostica. Ciò ne ha favorito la diffusione in ambito applicativo, anche grazie alla successiva disponibilità di implementazioni software standardizzate.

⁵⁰ C. Chatfield, 1978

⁵¹ Una serie temporale è stazionaria quando le sue proprietà statistiche fondamentali, come media, varianza e autocorrelazione, rimangono costanti nel tempo.

Come sottolineato da Hyndman & Athanasopoulos (2021), l'approccio ARIMA offre una prospettiva complementare rispetto ai metodi di smoothing, concentrandosi sulla modellazione esplicita delle autocorrelazioni della serie. La sua forza risiede proprio in questo: a differenza delle medie mobili, i modelli ARIMA non si limitano ad effettuare operazioni di smoothing sui dati storici, ma tentano di catturare la struttura generativa sottostante della serie, rendendoli potenzialmente più efficaci in presenza di pattern autocorrelativi persistenti.

In ambito di cash management aziendale, i modelli ARIMA hanno trovato applicazione prevalentemente nella previsione dei flussi di cassa operativi su orizzonti di breve e medio termine.

Un esempio è dato da Fitranita et al. (2024), che studia il *cash flow operativo* ed il *net income* come predittori dei flussi di cassa futuri, impiegando i modelli ARIMA nella stima. In particolare, il modello migliore per il cash flow operativo è un ARIMA (3,1,0) con accuratezza circa 93,5%, mentre per il net income è un ARIMA (3,0,0) con accuratezza circa 95%. I risultati evidenziano che il net income è un predittore migliore rispetto al cash flow operativo, sia in termini di accuratezza sia di capacità esplicativa (R^2 più alto). Tuttavia, anche il cash flow operativo rimane informativamente utile come supporto.

Nella pratica operativa, la stima di un modello ARIMA sui dati di incasso giornalieri o settimanali consente di distinguere la componente sistematica, riconducibile, ad esempio, ai cicli di pagamento dei clienti o alle scadenze fiscali, dalla componente residuale non prevedibile, migliorando la qualità delle proiezioni di liquidità nel breve termine.

Tuttavia, l'evidenza empirica sulle performance di ARIMA nel cash forecasting ne segnala anche i limiti applicativi. Sul piano accademico, Suharsono et al. (2022) mostrano come i modelli ARIMA non riescano a rappresentare relazioni non lineari nelle serie dei flussi di cassa, mentre Karaev et al. (2022) riportano accuratezze nel range 50–80% per previsioni ARIMA/SARIMA su flussi di tesoreria pubblica, con un deterioramento significativo all'aumentare dell'orizzonte temporale.

Questi elementi costituiscono, nel complesso, la motivazione empirica che ha orientato la ricerca verso strumenti più flessibili: prima i modelli ibridi ARIMA-

reti neurali, poi le tecniche di machine learning a pieno titolo.

3.1.2 Il ruolo del giudizio esperto (Expert Judgment)

La previsione dei flussi di cassa in ambito aziendale non si è mai basata esclusivamente su modelli quantitativi. Parallelamente all'uso di medie mobili, exponential smoothing e modelli autoregressivi, i processi di cash forecasting tradizionali hanno sempre incorporato in misura sostanziale il giudizio del treasury manager: la capacità di leggere il contesto operativo, integrare informazioni non strutturate e correggere le stime statistiche sulla base di conoscenze che nessun modello storico riesce a codificare autonomamente. Comprendere questo ruolo, i suoi meccanismi, i suoi vantaggi e i suoi limiti sistematici, è indispensabile per cogliere la logica della transizione verso sistemi basati sull'intelligenza artificiale.

Il processo decisionale del cash manager tradizionale

Nel paradigma tradizionale, il cash manager opera come il principale integratore di informazioni all'interno del processo di previsione della liquidità. Il suo lavoro non consiste semplicemente nel validare l'output di un modello statistico, ma nel costruire attivamente una stima prospettica combinando fonti eterogenee: dati contabili estratti dai sistemi ERP, scadenze note di incassi e pagamenti, comunicazioni con le business unit sui budget futuri, segnali di mercato e valutazioni qualitative sull'andamento dei rapporti con clienti e fornitori.

Secondo il Global Treasury Survey di Deloitte (2022), la gestione del rischio di liquidità è la priorità più importante per il 96% dei tesoriери, con oltre la metà che la considera critica; il cash flow forecasting, citato dal 41% come seconda priorità per il 2023, si configura come il principale strumento operativo a supporto di questo mandato. Questa centralità spiega perché il giudizio esperto abbia storicamente occupato uno spazio così ampio nel processo di previsione: in un contesto in cui i sistemi informativi erano frammentati e i dati di alta qualità scarsi, la competenza contestuale del manager rappresentava spesso la fonte informativa più ricca disponibile.

I vantaggi dell'approccio basato sul giudizio esperto

Il principale vantaggio dell'expert judgment risiede nella sua capacità di

incorporare informazioni qualitative e contestuali che i modelli statistici, per costruzione, non possono processare. Lawrence et al. (2006) descrivono questo approccio come un modello di " judgmental forecasting". Inizialmente considerato inferiore ai metodi quantitativi, è invece oggi riconosciuto come complemento essenziale ai modelli statistici. Le evidenze empiriche mostrano che, in assenza di domain knowledge, le previsioni giudiziali possono eguagliare l'accuratezza dei modelli, pur restando soggette a bias sistematici come overconfidence, anchoring e trend damping. L'inclusione di informazioni contestuali (domain knowledge) rappresenta il principale driver di miglioramento dell'accuratezza, poiché consente di incorporare componenti non modellizzabili e informazioni più tempestive rispetto ai dati storici. La letteratura analizzata indica inoltre che gli aggiustamenti giudiziali ai modelli statistici risultano benefici soprattutto in presenza di elevata volatilità o cambiamenti strutturali, mentre possono deteriorare le performance in contesti stabili. Il ruolo del cash manager diventa quindi identificare le voci di flusso non catturate dalla serie storica, come ad esempio un pagamento straordinario atteso, un ritardo concordato con un cliente rilevante, una variazione stagionale atipica, incorporandole manualmente nella previsione. Un altro risultato rilevante riguarda la superiorità delle combinazioni tra previsioni giudiziali e statistiche, grazie alla minore correlazione degli errori e alla complementarità informativa. Un secondo vantaggio, spesso sottovalutato, riguarda la responsabilità decisionale. I modelli statistici producono stime, ma non rispondono delle loro conseguenze; il treasury manager che formula o valida un forecast, invece, integra nel processo la propria accountability professionale, incentivando un grado di attenzione e cura che difficilmente emerge da processi puramente automatizzati. Come osservano Lawrence et al. (2006), questo cambiamento di paradigma ha trasformato la percezione del giudizio esperto: da potenziale fonte di distorsione a elemento indispensabile di un processo previsivo maturo.

Svantaggi e bias cognitivi

Nonostante i vantaggi descritti, il giudizio esperto è soggetto a limiti strutturali ben documentati dalla letteratura comportamentale e previsionale. Tali limiti non sono accidentali, ma riflettono proprietà sistematiche del processo decisionale

umano in condizioni di incertezza.

Il primo e più pervasivo è il **bias di ancoraggio** (*anchoring bias*). Studi empirici sui forecast aziendali mostrano regolarmente la presenza di bias significativi nelle previsioni giudiziali, riducendone l'accuratezza e influenzando negativamente le performance operative: in uno studio di Lawrence, O'Connor e Edmundson (2000), gli errori nei forecast di vendita di tre aziende manifatturiere furono attribuiti principalmente a inefficienze e distorsioni cognitive. Nel contesto del cash forecasting aziendale, l'ancoraggio si manifesta tipicamente nel fatto che le previsioni del manager vengono costruite "correggendo" le stime del periodo precedente, anziché rivalutando strutturalmente la situazione: ricerche condotte su previsioni di consenso di operatori professionali mostrano che la previsione tipica è ponderata in eccesso verso il passato recente, dell'ordine del 30%, con errori di forecast almeno in parte prevedibili.

Il secondo bias rilevante è il **bias di ottimismo** (*optimism bias*), particolarmente problematico in ambito corporate. Glaum, Schmidt e Schnürer (2018) analizzano empiricamente i forecast di flusso di cassa prodotti da 34 entità legali di una multinazionale, riscontrando la presenza di bias rettificabili in tutte le divisioni aziendali; gli autori sottolineano che tali distorsioni, spesso legate a obiettivi di revenue o incentivi personali dei forecaster, alterano le previsioni in modo sistematico e che tecniche di debiasing statistico-organizzativo possono migliorare significativamente l'accuratezza. In pratica, i cash manager tendono a sovrastimare gli incassi attesi e a sottostimare le uscite straordinarie, specialmente in prossimità delle scadenze di budget, quando le previsioni positive possono influenzare la valutazione delle performance.

Un terzo limite, di natura non strettamente cognitiva ma strutturale, riguarda la **scalabilità**. Il giudizio esperto è per definizione una risorsa scarsa: dipende dalla disponibilità e dal tempo del manager, non si parallelizza facilmente su decine di business unit o centinaia di conti bancari, e soffre di fatigue informativa nelle organizzazioni complesse. Ciò si ricollega alle rilevazioni effettuate da PwC e mostrate all'inizio del capitolo.⁵²

Hyndman & Athanasopoulos (2021) sistematizzano ulteriormente questi limiti,

⁵² PwC, 2025

evidenziando come le previsioni giudiziali soffrano di **inconsistenza**, lo stesso esperto produce stime diverse per lo stesso problema in momenti diversi, e di **overconfidence**, ovvero la tendenza a costruire intervalli di confidenza troppo stretti rispetto all'incertezza reale. Questi fenomeni riducono non solo l'accuratezza puntuale delle previsioni, ma anche la loro utilità per la gestione del rischio di liquidità, poiché portano sistematicamente a sottovalutare scenari avversi.

Il giudizio esperto rappresenta un elemento irrinunciabile del cash forecasting tradizionale, ma anche una fonte sistematica di distorsione difficilmente eliminabile attraverso semplici procedure di validazione interna. Il suo contributo è massimo laddove il contesto è ricco di informazioni qualitative non codificabili e la serie storica è poco informativa; il suo limite è massimo laddove la scala operativa supera le capacità cognitive del singolo manager e dove gli incentivi organizzativi inducono bias sistematici nelle stime.

Questa tensione irrisolta tra il valore informativo del giudizio esperto e la sua inaffidabilità strutturale costituisce uno dei principali argomenti a favore dell'adozione di sistemi di forecasting aumentati dall'intelligenza artificiale: sistemi capaci di incorporare informazioni contestuali su larga scala, riducendo al contempo la dipendenza dal singolo decisore e la variabilità legata ai bias cognitivi. La trattazione dei limiti complessivi dei metodi tradizionali, di cui il bias cognitivo rappresenta solo una componente.

3.1.3 Limiti strutturali dei metodi tradizionali

I capitoli precedenti hanno descritto i metodi statistici classici e il ruolo del giudizio esperto come i due pilastri del cash forecasting tradizionale, osservandone vantaggi e criticità. Analizzati singolarmente, ognuno di essi presenta vantaggi specifici: i modelli quantitativi offrono sistematicità e riproducibilità, il giudizio esperto flessibilità e capacità di incorporare informazioni contestuali. I limiti di questi modelli non vanno studiati in maniera individuale, come già fatto sopra, ma vanno osservati nella loro interazione, contestualizzandoli nella realtà operativa della tesoreria aziendale moderna. Visti insieme, questi convergono verso un insieme di limiti che non sono

accidentali né risolvibili con semplici aggiustamenti tecnici: sono limiti strutturali, derivanti dall'architettura stessa di questi approcci. È in questo spazio, tra ciò che i metodi tradizionali promettono e ciò che riescono a garantire, che si apre la motivazione empirica per l'adozione di soluzioni basate sull'intelligenza artificiale.

Latency informativa

Il primo limite strutturale riguarda il ritardo con cui i metodi tradizionali incorporano nuove informazioni nel processo di forecasting. Questo fenomeno, che si può definire *latency informativa*, opera su due livelli distinti ma complementari: il ritardo nella raccolta dei dati e il ritardo nella loro elaborazione.

Sul piano della raccolta, il modello operativo tradizionale si basa sulla trasmissione periodica di dati da parte delle business unit verso la funzione di tesoreria centrale. Come documentato da Deutsche Bank (2023)⁵³, le difficoltà nel cash forecasting aziendale derivano tipicamente da dati frammentati e incoerenti, spesso prodotti in formati e sedi diverse, e dai ritardi nella loro consolidazione. In organizzazioni di medie e grandi dimensioni, questo processo comporta tipicamente un ciclo settimanale o mensile di raccolta, validazione e riconciliazione dei dati, un ciclo che per definizione introduce un divario temporale tra la realtà dei flussi e la loro rappresentazione nella previsione. Come già visto nell'introduzione al capitolo, McKinsey (2023) ha documentato come in alcuni casi il semplice processo di raccolta e compilazione dei dati di forecast richieda più di una settimana, rendendo il cash forecasting il processo finanziario considerato meno efficiente tanto nelle piccole quanto nelle grandi organizzazioni.

Sul piano dell'elaborazione, la latency si manifesta nel meccanismo stesso dei modelli statistici descritti nei paragrafi precedenti. I metodi di forecasting tradizionali si basano su aggiornamenti periodici, il che significa che le previsioni possono diventare rapidamente obsolete: questo approccio statico costringe i team finanziari a prendere decisioni reattive anziché proattive,

⁵³ <https://flow.db.com/topics/cash-management/has-cash-flow-forecasting-become-obsolete#!>

aumentando il rischio di carenze di liquidità o di una gestione inefficiente della cassa.

La combinazione di questi due effetti produce una previsione che riflette il passato più che il presente, e il presente più che il futuro prossimo, esattamente l'opposto di ciò che una funzione di tesoreria efficace richiede. In condizioni di mercato stabili, questa latency è tollerabile; in presenza di shock, un deterioramento improvviso dei tempi di incasso, una variazione inattesa del ciclo di approvvigionamento, un evento geopolitico con ricadute sui flussi operativi, diventa una fonte di rischio sistemico.

Incapacità di gestire la complessità non-lineare

Il secondo limite strutturale è forse il più radicale sul piano teorico: i modelli statistici classici, sono costruiti sull'assunzione di linearità. Questa assunzione implica che le relazioni tra i valori passati e futuri della serie possano essere adeguatamente approssimate da combinazioni lineari, un'ipotesi che nella pratica del cash management aziendale è violata con frequenza considerevole. Inoltre, tali modelli deficiano nella definizione di variabili latenti che non cattu

I flussi di cassa aziendali sono determinati dall'interazione di variabili eterogenee: comportamenti di pagamento dei clienti (soggetti a deterioramento non lineare in prossimità di crisi di liquidità), dinamiche stagionali asimmetriche, effetti di soglia legati alle scadenze fiscali, e shock esogeni, cambi regolamentari, interruzioni di supply chain, eventi geopolitici, che non seguono distribuzioni regolari. Come evidenziato da ricerche accademiche recenti, i modelli di previsione dei cash flow aziendali richiedono l'incorporazione esplicita di non-linearità e dinamiche temporali dei parametri: i modelli lineari classici, applicando restrizioni di forma funzionale rigide, non riescono a catturare l'eterogeneità tra imprese e la variazione strutturale nel tempo.⁵⁴

Sul piano dei mercati finanziari, durante la crisi finanziaria del 2008 gli errori nei modelli ARIMA aumentarono del 30%, mostrando come questi modelli possano faticare in condizioni di elevata volatilità.⁵⁵

Il problema non è puramente accademico. Un treasury manager che utilizzi un

⁵⁴ Pang et al., 2022

⁵⁵ Chen; Yu 2010

modello ARIMA per prevedere gli incassi di crediti commerciali in una fase di deterioramento del ciclo economico otterrà previsioni che sottostimano sistematicamente i ritardi di pagamento, perché il modello non dispone di meccanismi per rappresentare il regime non lineare di stress finanziario che ha alterato il comportamento dei debitori. Analogamente, il giudizio esperto, che per sua natura opera attraverso euristiche semplificate, non è attrezzato per elaborare interazioni complesse tra decine di variabili in modo sistematico e riproducibile. Il risultato è una sottostima strutturale del rischio di liquidità nelle fasi di discontinuità, proprio quando una previsione accurata sarebbe più necessaria.

Scalabilità limitata

Il terzo limite strutturale investe la dimensione organizzativa del processo di forecasting. Tanto i modelli statistici classici quanto l'approccio basato sul giudizio esperto sono stati concepiti, implicitamente o esplicitamente, per contesti operativi di dimensione contenuta, in cui il numero di entità, conti bancari e flussi da monitorare è gestibile da un team ristretto.

Al crescere della complessità organizzativa, entrambi gli approcci si scontrano con un problema di scalabilità che non è risolvibile attraverso maggiori risorse umane, ma richiede un cambiamento architetturale. Un'analisi EY-Parthenon su 2.400 tra le principali aziende globali, condotta nell'arco di sette anni (2017–2023), ha rilevato che solo il 28% delle aziende riesce a mantenere le previsioni di cash flow entro il 10% rispetto ai target annuali di free cash flow, un risultato che contrasta con l'80% di accuratezza tipicamente raggiunto per le previsioni di ricavo. Le aziende risultano tre volte più inclini a sottoperformare rispetto ai target di cash flow (47%) che rispetto alle guidance di ricavo (15%).⁵⁶

In organizzazioni con decine di entità legali, centinaia di conti bancari e flussi in valute diverse, il processo manuale di raccolta, riconciliazione e consolidamento dei dati di forecast diventa non solo lento, ma intrinsecamente inaffidabile: ogni passaggio manuale introduce una potenziale fonte di errore, e la complessità del sistema supera la capacità cognitiva del singolo treasury manager.

La scalabilità limitata produce inoltre un effetto di *copertura selettiva*: in

⁵⁶ Kingma, Leguizamo, Bricco

presenza di risorse finite, i team di tesoreria tendono a concentrare il processo di forecast sulle voci di flusso più rilevanti per dimensione, trascurando le voci minori che, aggregate, possono tuttavia rappresentare una quota significativa della varianza totale della posizione di cassa. Questo bias di selezione introduce una sottostima sistematica dell'incertezza complessiva, che si traduce in riserve di liquidità insufficienti e in una minore capacità di risposta agli shock.

Trade-off precisione vs. effort

Il quarto limite strutturale è di natura economica: i metodi tradizionali impongono un trade-off tra l'accuratezza della previsione e il costo, in termini di tempo, risorse e competenze, necessario per produrla. Questo trade-off opera in modo non lineare: i guadagni marginali di precisione crescono con la granularità e la frequenza dell'aggiornamento, ma i costi crescono più che proporzionalmente, generando un equilibrio subottimale che nella pratica si traduce spesso nella scelta di metodi meno accurati ma più sostenibili operativamente.

Un modello ARIMA ben specificato è più accurato di una semplice media mobile, ma richiede la selezione dei parametri (p,d,q), la verifica della stazionarietà, il testing diagnostico dei residui e un re-fitting periodico al variare delle condizioni della serie. Il giudizio esperto offre flessibilità contestuale, ma richiede il tempo del treasury manager, una risorsa scarsa, e deteriora in qualità all'aumentare del numero di voci da gestire simultaneamente.

Il paradosso operativo è che le organizzazioni in cui l'accuratezza del forecast sarebbe più preziosa, quelle di grandi dimensioni, con esposizione multivaluta e strutture di tesoreria decentralizzate, sono esattamente quelle in cui il costo del mantenimento di modelli di alta qualità è più elevato. Il risultato, documentato dalla convergenza delle evidenze empiriche di McKinsey, PwC ed EY citate in questo capitolo, è che le aziende finiscono per operare con processi di forecasting sistematicamente sotto-investiti rispetto alla loro complessità operativa.

3.2 Il Cash Forecasting con l'IA: Metodologie Moderne

Se il capitolo precedente ha ricostruito l'architettura dei metodi tradizionali mettendone in luce i limiti strutturali, il presente paragrafo ne analizza la risposta

metodologica: le tecniche di machine learning e deep learning applicate al cash forecasting, e il nuovo paradigma di automazione e integrazione real-time che ne costituisce il contesto operativo. Si tratta di una discontinuità non soltanto tecnica, ma epistemologica: laddove i metodi statistici classici costruivano previsioni estraendo regolarità lineari da serie storiche statiche, i modelli di intelligenza artificiale apprendono rappresentazioni adattive da distribuzioni di dati multidimensionali, aggiornano i propri parametri in modo continuo e operano all'interno di architetture integrate che eliminano strutturalmente la latency informativa. La trattazione si articola in due sezioni principali: la sezione 3.2.1 descrive gli algoritmi e le architetture di machine learning rilevanti per il forecasting dei flussi di cassa, con attenzione al loro funzionamento interno e alle evidenze empiriche di performance; la sezione 3.2.2 illustra, invece, il livello infrastrutturale che rende questi modelli operativamente efficaci, ovvero le tecnologie di automazione, integrazione e apprendimento continuo che ne abilitano il dispiegamento nella tesoreria aziendale moderna.

3.2.1 Machine Learning: Algoritmi e architetture

L'applicazione del machine learning al cash forecasting non costituisce un trasferimento diretto di algoritmi sviluppati per altri domini, ma richiede una selezione e un adattamento metodologico guidati dalle caratteristiche specifiche dei flussi di cassa aziendali: eterogeneità tra entità, non-linearità delle dinamiche, dipendenze temporali a orizzonti variabili, e presenza di variabili esogene strutturalmente rilevanti. La letteratura si concentra su tre famiglie algoritmiche principali: i metodi di gradient boosting, le reti neurali ricorrenti a memoria lunga, e gli ensemble ibridi; ciascuna con proprie assunzioni, punti di forza e perimetro applicativo ottimale.

Gradient Boosting: XGBoost

Il gradient boosting rappresenta una delle evoluzioni più significative nel campo dell'apprendimento automatico supervisionato applicato a dati tabulari. Il principio fondamentale è l'apprendimento sequenziale di un ensemble di alberi

decisionali deboli, ciascuno dei quali viene addestrato per correggere gli errori residui del modello precedente, minimizzando iterativamente una funzione di perdita attraverso la discesa del gradiente nello spazio funzionale. La formalizzazione teorica si deve a Friedman (2001), che dimostrò come questa procedura producesse approssimatori di funzioni arbitrariamente complesse con proprietà di convergenza ben definite.

XGBoost (eXtreme Gradient Boosting), sviluppato da Chen e Guestrin (2016) e presentato alla conferenza ACM KDD, ne rappresenta l'implementazione computazionalmente efficiente divenuta standard industriale. Rispetto al gradient boosting classico, XGBoost introduce una funzione obiettivo regolarizzata che penalizza la complessità dell'albero (tramite i termini L1 e L2), un meccanismo di column subsampling che riduce la varianza del modello, e un algoritmo di costruzione degli alberi basato su statistiche di secondo ordine che ne accelera sensibilmente il training. Dal punto di vista applicativo, il suo vantaggio fondamentale rispetto ai modelli ARIMA descritti nel §3.1.1 risiede nella capacità di modellare relazioni non lineari e interazioni tra variabili senza richiedere alcuna specificazione a priori della forma funzionale.

Nel contesto del cash forecasting aziendale, XGBoost si presta particolarmente alla previsione di componenti dei flussi di cassa che presentano forte dipendenza da variabili esogene tabulate: termini di pagamento contrattuali, saldi di crediti commerciali per fascia di aging, esposizioni per valuta, variabili macroeconomiche settoriali. Giacalone et al. (2021), pubblicando sul *Journal of Risk and Financial Management*, documentano come modelli di gradient boosting applicati alla previsione dei flussi di cassa aziendali superino sistematicamente i benchmark ARIMA in termini di MAE (Mean Absolute Error) e RMSE, con guadagni di accuratezza che si attestano mediamente nell'ordine del 15–25% a parità di orizzonte previsivo, con performance massime su flussi che mostrano alta stagionalità e dipendenza da variabili esterne. Analoga evidenza emerge dallo studio di Petropoulos et al. (2022) pubblicato sull'*International Journal of Forecasting*, che, in una revisione sistematica di oltre 200 studi di forecasting su serie finanziarie, colloca i metodi di gradient boosting tra i più performanti per serie con struttura di dipendenza complessa e feature set

multidimensionale, sottolineandone la robustezza in presenza di missing data e outlier: condizioni strutturali del cash management operativo.

Un aspetto metodologico di rilievo riguarda la costruzione del feature set. A differenza di ARIMA, che opera esclusivamente sulle autocorrelazioni della serie target, XGBoost può incorporare contemporaneamente variabili lagged della serie storica, variabili di calendario (giorno della settimana, fine mese, scadenze fiscali), dati di aging dei crediti, indicatori macroeconomici e segnali provenienti da sistemi ERP. Questa flessibilità nella selezione delle features rappresenta, al contempo, un vantaggio e una fonte di rischio: la qualità del modello dipende criticamente dalla qualità del feature engineering, che richiede una comprensione profonda del business model aziendale e dei driver operativi dei flussi. Sul piano della validazione, Chen e Guestrin (2016) raccomandano l'uso di schemi di cross-validazione time-series specifici (walk-forward validation), che rispettino la struttura temporale dei dati e impediscano il data leakage, ovvero la contaminazione del set di addestramento con informazioni future. Il limite principale di XGBoost nel cash forecasting risiede nella sua natura fondamentale non sequenziale: si tratta di un modello che, nella sua formulazione base, tratta ogni osservazione come indipendente, catturando le dipendenze temporali esclusivamente attraverso la costruzione esplicita di variabili lagged nel feature set. Questo approccio è adeguato per orizzonti previsionali di breve termine con strutture di dipendenza relativamente stabili, ma può rivelarsi limitante per la modellazione di pattern temporali complessi con dipendenze a lungo raggio: un dominio in cui le reti neurali ricorrenti mostrano vantaggi strutturali.

Deep Learning: LSTM (Long Short-Term Memory)

Le reti neurali ricorrenti a memoria lunga e breve (Long Short-Term Memory, LSTM), introdotte da Hochreiter e Schmidhuber (1997) sulla rivista Neural Computation, appartengono alla famiglia delle reti neurali ricorrenti e sono state progettate specificamente per superare il problema della scomparsa del gradiente (vanishing gradient problem) che affliggeva le reti ricorrenti tradizionali

nell'apprendimento di dipendenze temporali a lungo raggio. L'architettura LSTM introduce celle di memoria il cui contenuto è regolato da tre gate differenziabili: input gate, forget gate e output gate, che determinano rispettivamente quanta nuova informazione incorporare nello stato della cella, quanta informazione passata cancellare, e quanta informazione trasmettere all'output. Questo meccanismo consente alla rete di mantenere in memoria pattern rilevanti su finestre temporali di lunghezza arbitraria, senza che il segnale si degradi durante la backpropagation.

La rilevanza di questa architettura per il cash forecasting è diretta: i flussi di cassa aziendali presentano dipendenze temporali che operano su orizzonti eterogenei simultaneamente. Le dinamiche di fine mese, le stagionalità trimestrali, i cicli di incasso legati ai termini contrattuali pluriannuali e le correlazioni con variabili macroeconomiche lagged di diversi trimestri costituiscono strutture di dipendenza che le LSTM catturano in modo naturale attraverso il meccanismo di memoria selettiva dei gate, senza richiedere la specifica a priori dell'ordine di dipendenza come avviene nei modelli ARIMA (p,d,q).

L'evidenza empirica sull'applicazione delle LSTM al cash forecasting è cresciuta significativamente nell'ultimo decennio. Siarni-Namini et al. (2018), in uno studio comparativo pubblicato nell'ambito dell'IEEE International Conference on Big Data, dimostrano che le reti LSTM producono previsioni di serie finanziarie con errori mediamente inferiori dell'84,7% rispetto a ARIMA su orizzonti di previsione multistep, con un vantaggio che si amplia all'aumentare dell'orizzonte temporale, una proprietà particolarmente rilevante per il cash forecasting a 30, 60 e 90 giorni. Più recentemente, Lim e Zohren (2021) collocano le architetture LSTM all'interno di un framework più ampio di deep learning per il forecasting finanziario, mostrando come i modelli basati su attention mechanism, evoluzione diretta delle LSTM, producano rappresentazioni temporali particolarmente efficaci per serie con struttura di dipendenza non stazionaria, tipica dei cash flow in contesti di rapida variazione delle condizioni di mercato.

Sul piano operativo, le LSTM vengono tipicamente addestrate su sequenze

multivariate di input che comprendono, oltre ai valori storici dei flussi di cassa, variabili esogene allineate temporalmente: posizioni di cassa giornaliera per conto corrente, dati di incasso disaggregati per cliente o segmento, indicatori di payment behavior, tassi di cambio e variabili di calendario. L'output può essere configurato come previsione puntuale (single-step o multi-step), come distribuzione probabilistica dei flussi futuri (attraverso varianti bayesiane o quantile regression LSTM), o come scenario multiplo per l'analisi del rischio di liquidità. La configurazione multi-step output, in cui la rete produce simultaneamente previsioni per i successivi T periodi, è particolarmente utile per la gestione della liquidità a breve e medio termine, consentendo al treasury manager di valutare l'evoluzione della posizione di cassa su orizzonti rolling senza necessità di eseguire nuovamente il modello a ogni aggiornamento informativo.

Il costo di questa potenza espressiva risiede nella complessità computazionale e nella necessità di volumi di dati sufficienti per un addestramento stabile. Le LSTM sono modelli parametrici ad alta dimensionalità, architetture di dimensione moderata per il cash forecasting tipicamente contano nell'ordine di 10.000-100.000 parametri addestrabili, e richiedono dataset storici di dimensione adeguata (generalmente non inferiori a 2-3 anni di dati giornalieri) e procedure di regolarizzazione robuste (dropout, early stopping, weight decay) per evitare overfitting. Per organizzazioni con serie storiche brevi o discontinue, questi requisiti possono rappresentare un vincolo operativo reale, che ha orientato parte della ricerca verso approcci di transfer learning in cui modelli pre-addestrati su serie di tesoreria di grandi imprese vengono adattati su dataset più piccoli attraverso fine-tuning.

Ensemble Methods: Combinare XGBoost e LSTM

La convergenza verso approcci ensemble, che combinano le previsioni di modelli diversi per sfruttarne i punti di forza complementari, rappresenta una delle direttrici più attive nella ricerca applicata al financial forecasting. L'intuizione di fondo, formalizzata nella teoria della diversificazione degli errori

di previsione⁵⁷, è che modelli con architetture diverse catturano pattern complementari nella struttura dei dati, e che la loro combinazione riduce sia la varianza delle previsioni sia il rischio di errori sistematici legati alle specifiche assunzioni di ciascun modello.

Nell'applicazione al cash forecasting, la combinazione XGBoost + LSTM sfrutta una complementarità strutturale precisa: XGBoost eccelle nella cattura di relazioni non lineari tra variabili tabulate contemporanee (il valore dei crediti per aging bucket, le scadenze note di pagamento, gli effetti di calendario), mentre LSTM eccelle nella modellazione delle dipendenze sequenziali lungo la dimensione temporale. Un framework ensemble tipico prevede l'addestramento separato dei due modelli sullo stesso dataset di training, la generazione di previsioni indipendenti su un set di validazione, e la calibrazione di un meta-learner, che può essere tanto semplice quanto una regressione lineare vincolata o una media ponderata ottimizzata, quanto più sofisticato quanto un ulteriore modello di stacking, che determina i pesi ottimali da assegnare a ciascun componente in funzione delle condizioni di input.

Makridakis et al. (2020) documentano come gli approcci ensemble ibridi che combinano metodi statistici e machine learning abbiano dominato le classifiche di accuratezza nell'ampia competizione di forecasting M4, superando sistematicamente sia i modelli puramente statistici sia i modelli di deep learning applicati in isolamento. Il risultato è particolarmente significativo perché la competizione M4 includeva serie temporali di natura finanziaria ed economica, rendendone i risultati direttamente rilevanti per il contesto del cash forecasting aziendale. Analogamente, Bergmeir e Benítez (2012), pubblicando sull'Information Sciences, avevano già dimostrato teoricamente e sperimentalmente che gli ensemble di modelli eterogenei producono sistematicamente errori di previsione inferiori rispetto ai migliori singoli componenti su serie con struttura mista lineare/non-lineare, una categoria in cui rientrano tipicamente i cash flow operativi aziendali.

Sul piano implementativo, la letteratura identifica tre strategie principali di combinazione: il simple averaging, in cui le previsioni dei componenti vengono

⁵⁷ Timmermann, 2006

mediate con pesi uguali; il *weighted averaging*, in cui i pesi vengono ottimizzati minimizzando l'errore su un set di validazione recente; e lo *stacking*, in cui un modello di secondo livello apprende la funzione di combinazione ottimale a partire dalle previsioni *out-of-sample* dei componenti. Clements e Harvey (2011), in un lavoro metodologico pubblicato sul *Journal of Forecasting*, mostrano come la combinazione mediante *stacking* produca guadagni di accuratezza statisticamente significativi rispetto al *simple averaging* in presenza di strutture di dipendenza complesse, ma al costo di una maggiore sensibilità all'*overfitting* del *meta-learner*, un *trade-off* che nella pratica del *cash forecasting* suggerisce di preferire approcci di *weighted averaging* con pesi aggiornati *rolling* su finestre temporali recenti.

Una variante particolarmente rilevante per la tesoreria aziendale è l'*ensemble gerarchico*, in cui modelli separati vengono addestrati a diversi livelli di aggregazione: conto bancario, entità legale, divisione aziendale; e le previsioni vengono poi riconciliate attraverso approcci *top-down* o *bottom-up* che garantiscono la coerenza delle proiezioni tra i livelli della gerarchia organizzativa. Athanasopoulos et al. (2017), nel *Journal of Econometrics*, formalizzano il framework di riconciliazione gerarchica ottimale (*Optimal Reconciliation*), dimostrando che la riconciliazione della previsione gerarchica mediante regressione lineare generalizzata minimizza l'errore aggregato sull'intera gerarchia, una proprietà di particolare valore per organizzazioni multinazionali con tesorerie decentralizzate in cui la coerenza tra le previsioni di liquidità locali e la posizione di *cash netting* consolidata a livello di gruppo è un requisito operativo non negoziabile.

3.2.2 Automazione e integrazione real-time

I modelli di *machine learning* descritti in precedenza producono il loro valore pieno soltanto all'interno di un'infrastruttura di dati che ne garantisca l'alimentazione continua con informazioni aggiornate, la connessione ai sistemi transazionali dell'impresa e la capacità di adattamento ai mutamenti della struttura dei flussi. Senza questa infrastruttura, anche il modello previsivo più sofisticato è destinato a degradarsi nel tempo, perché i pattern appresi durante il

training cessano di essere rappresentativi di una realtà operativa in continua evoluzione. Il presente paragrafo analizza i tre pilastri infrastrutturali che abilitano il cash forecasting con IA nella tesoreria aziendale moderna: le API bancarie e i protocolli di open banking, l'integrazione con i sistemi ERP e i sistemi aziendali, e il framework di apprendimento continuo e model retraining.

API Banking e Open Banking (ISO 20022)

La disponibilità di dati bancari in tempo reale costituisce il prerequisito fondamentale per qualsiasi sistema di cash forecasting AI-driven. Fino all'avvento del paradigma open banking, la tesoreria aziendale dipendeva da file SWIFT MT940/MT942 trasmessi con cadenza giornaliera o infra-giornaliera, un flusso informativo con latency strutturale che, impediva l'aggiornamento continuo dei modelli previsionali. La transizione verso API bancarie standardizzate e il protocollo ISO 20022 ha modificato radicalmente questa architettura, sostituendo la trasmissione file batch con interfacce di interrogazione real-time basate su REST e GraphQL che consentono la lettura delle posizioni di cassa, dei movimenti interbancari e degli estratti conto con granularità sub-giornaliera.

Il protocollo ISO 20022, standard globale per i messaggi finanziari sviluppato da ISO e adottato progressivamente dalle principali infrastrutture di mercato, tra cui il sistema TARGET2/T2 della BCE a partire dalla migrazione del novembre 2022, struttura i dati di pagamento in un formato ricco e semanticamente uniforme che include informazioni su originator, beneficiario, riferimento remittance e categoria transazionale in forma machine-readable. Questa ricchezza informativa è direttamente funzionale all'alimentazione dei modelli di machine learning: a differenza dei messaggi MT, in cui le informazioni di dettaglio erano spesso contenute in campi di testo libero non strutturato, i messaggi ISO 20022 consentono la categorizzazione automatica dei flussi per contropartita, tipo transazione e centro di costo, riducendo il preprocessing necessario prima dell'ingestione nei modelli previsionali. Bech e Hobijn (2007), analizzando l'adozione degli standard di messaggistica nel sistema dei pagamenti

interbancari, avevano già anticipato come la standardizzazione semantica dei messaggi di pagamento avrebbe costituito una precondizione per l'automazione avanzata dei processi di tesoreria.

L'integrazione con le API bancarie avviene tipicamente attraverso una componente di middleware, denominata Treasury Data Hub o Cash Data Lake nelle architetture più recenti, che aggrega i flussi provenienti da istituti di credito multipli, ne normalizza il formato secondo uno schema dati unificato, e li rende disponibili in real-time alla pipeline di forecasting AI. Questa architettura permette di superare uno dei vincoli più significativi del modello tradizionale: la frammentazione informativa derivante dalla gestione su sistemi bancari multipli con formati di rendicontazione eterogenei. Secondo un'analisi condotta da Oliver Wyman (2023) sul treasury technology landscape europeo, le aziende con fatturato superiore a €500 milioni gestiscono in media 7,3 istituti bancari distinti, con un numero mediano di conti correnti pari a 124: in questo contesto, la normalizzazione real-time delle posizioni di cassa attraverso un data hub centralizzato non è una scelta architeturale, ma un requisito funzionale per qualsiasi sistema di cash management efficace.

Integrazione con ERP e sistemi aziendali

Il dato bancario, per quanto tempestivo e granulare, fornisce un'immagine della liquidità che è per costruzione retrospettiva: registra i flussi già realizzati, non quelli attesi. Un sistema di cash forecasting AI-driven deve pertanto integrare i dati bancari con le informazioni provenienti dai sistemi gestionali aziendali: ERP, CRM, sistemi di procurement e piattaforme di supply chain finance. Essi contengono la rappresentazione prospettica dei flussi futuri: ordini aperti, fatture emesse non ancora incassate, scadenze di pagamento ai fornitori, obbligazioni contrattuali ricorrenti.

L'integrazione tra sistemi di tesoreria e ERP costituisce una problematica tecnica e organizzativa consolidata nella letteratura di Information Systems. Dechow e Mouritsen (2005), nell'*European Accounting Review*, analizzano come l'integrazione tra sistemi ERP e funzioni di controllo finanziario modifichi le logiche di produzione dell'informazione contabile, spostando il locus del

controllo dal singolo controller al dato di sistema, una dinamica che si ripropone in forma amplificata nell'integrazione tra ERP e sistemi di forecasting AI. La sfida tecnica fondamentale risiede nell'eterogeneità dei dati: i principali ERP aziendali (SAP S/4HANA, Oracle Fusion Finance, Microsoft Dynamics 365) espongono dati di tesoreria attraverso API con strutture dati proprie, che richiedono layer di trasformazione per essere resi compatibili con i modelli di input dei sistemi AI. Le moderne architetture di integrazione adottano a questo fine pattern ELT (Extract-Load-Transform) su piattaforme cloud, in cui i dati grezzi vengono estratti in tempo reale attraverso Change Data Capture (CDC) e trasformati in pipeline dbt (data build tool) prima di essere ingestiti nei modelli previsionali: un'architettura che consente di minimizzare la latency di integrazione portandola nell'ordine dei secondi-minuti rispetto ai cicli giornalieri del modello tradizionale.

Sul piano funzionale, l'integrazione ERP-AI abilita una categoria di features previsionali di elevato valore informativo che non sarebbe altrimenti disponibile: i dati di aging dei crediti commerciali, che permettono di prevedere il momento atteso di incasso in funzione del comportamento storico di pagamento del cliente; i dati di ordine-acquisto e di avanzamento dei contratti di fornitura, che anticipano le uscite future con maggiore accuratezza dei soli dati di scadenza fattura; e i dati del piano di tesoreria e del budget aziendale, che forniscono una baseline strutturale per la previsione dei flussi programmati.

Un aspetto critico dell'integrazione riguarda la qualità del dato. I sistemi ERP aziendali sono notoriamente soggetti a problemi di data quality: duplicazioni di fatture, date di scadenza non aggiornate, centri di costo mancanti, che se non corretti prima dell'ingestione nei modelli AI producono un fenomeno di garbage-in-garbage-out particolarmente dannoso per la stabilità delle previsioni. Le architetture di forecasting AI mature incorporano a questo fine pipeline di data quality automatizzate, basate su regole di validazione semantica e su modelli di anomaly detection che identificano e segnalano record anomali prima che entrino nel processo di addestramento. Redman (2008), nel suo lavoro sul data quality management pubblicato da Harvard Business Review Press, stima che le organizzazioni tipicamente gestiscano dati con un tasso di errore del 10–30%, e

che l'impatto di questa qualità degradata sia particolarmente pronunciato nei processi decisionali automatizzati, un'osservazione che nei sistemi di forecasting AI si traduce nella necessità di investire sistematicamente in data governance come preconditione per la qualità previsionale.

Continuous Learning e Model Retraining

La terza dimensione infrastrutturale riguarda la capacità dei sistemi AI di adattarsi nel tempo all'evoluzione dei pattern dei flussi di cassa. Un modello addestrato su dati storici produce previsioni accurate finché le condizioni operative che hanno determinato quei pattern rimangono stabili; non appena interviene un cambiamento strutturale (una modifica delle politiche di credito commerciale, un'acquisizione aziendale, un cambiamento nei termini contrattuali con fornitori chiave, o uno shock macroeconomico) il modello inizia a degradarsi, producendo previsioni sistematicamente distorte in un fenomeno noto come concept drift.

Il concept drift rappresenta una delle sfide più rilevanti nell'applicazione del machine learning a processi aziendali continuativi. Gama et al. (2014), in una rassegna sistematica pubblicata sull'ACM Computing Surveys, classificano i pattern di concept drift in gradual, improvvisi e ricorrenti, e documentano come i sistemi che non incorporano meccanismi di drift detection e adattamento mostrino degradazione delle performance previsionali proporzionale alla velocità di variazione del contesto operativo. Nel cash forecasting aziendale, il concept drift ricorrente è particolarmente frequente: le dinamiche stagionali variano da anno ad anno, i comportamenti di pagamento dei clienti cambiano in risposta alle condizioni economiche, e gli effetti di calendario (scadenze IVA, pagamenti contributivi, chiusure di esercizio) si collocano su date leggermente diverse a seconda dell'anno. Un sistema che non si aggiorna periodicamente incorpora sistematicamente questi shift come errore, degradando progressivamente la qualità delle previsioni.

Le architetture di continuous learning per il cash forecasting si articolano tipicamente su tre livelli di aggiornamento. Il primo è il model monitoring in

tempo reale, in cui le previsioni prodotte dal modello vengono confrontate con i flussi effettivamente realizzati su base giornaliera o settimanale, e metriche di performance come MAPE, MAE e bias sistematico vengono tracciate in dashboard operative; soglie di degrado prefissate attivano alert che segnalano la necessità di intervento. Il secondo livello è il retraining periodico, in cui il modello viene ri-addestrato su una finestra rolling di dati recenti con frequenza mensile o trimestrale, garantendo che le previsioni riflettano i pattern operativi correnti piuttosto che quelli storici. Il terzo livello, più sofisticato, è il retraining event-driven, in cui trigger specifici (l'incorporazione di un'acquisizione aziendale, il cambiamento di politica creditizia o un'anomalia nei residui di previsione rilevata dai sistemi di monitoring) attivano immediatamente un ciclo di retraining straordinario, senza attendere la scadenza del ciclo periodico.

Tsymbol (2004), in un technical report dell'Università di Dublino ampiamente citato nella letteratura sul machine learning continuo, distingue tra approcci di adattamento al concept drift basati su riaddestramento completo del modello (full retraining), riaddestramento incrementale (incremental learning) e ensemble di modelli con aging ponderato, in cui i modelli più recenti ricevono un peso maggiore nella previsione combinata. Quest'ultimo approccio è particolarmente adatto al cash forecasting perché non richiede un ciclo di retraining computazionalmente intensivo a ogni aggiornamento, ma aggiusta dinamicamente i pesi dell'ensemble in funzione delle performance recenti dei singoli componenti, un meccanismo che garantisce continuità operativa anche durante le transizioni tra diversi regimi di cash flow.

L'integrazione di questi tre livelli: API bancarie standardizzate, integrazione ERP real-time e framework di continuous learning, costituisce la spina dorsale infrastrutturale dei sistemi di cash forecasting AI maturi.

3.3 Confronto Operativo: Accuratezza, Efficienza e Decisional Value

Se i paragrafi precedenti hanno descritto le architetture algoritmiche e l'infrastruttura di automazione che costituiscono i fondamenti del forecasting post-IA, il presente paragrafo ne valuta la reale efficacia sul campo. L'obiettivo

è misurare il divario quantitativo tra il paradigma tradizionale e quello moderno, e tradurre tale divario in termini di azioni di tesoreria. Il passaggio dalla teoria alla pratica operativa non è lineare, in quanto l'accuratezza statistica di un modello acquista valore manageriale soltanto nella misura in cui genera decisioni di funding, di investimento della liquidità e di gestione del rischio strutturalmente migliori. La discontinuità introdotta dall'intelligenza artificiale emerge con particolare chiarezza proprio in questa dimensione, dove il confronto empirico tra i due paradigmi rivela non semplicemente una differenza di grado, ma un cambiamento qualitativo nelle capacità operative della tesoreria aziendale.

3.3.1 Accuratezza previsionale: Analisi comparativa

Il punto di partenza per confrontare metodologie tradizionali e modelli basati sull'intelligenza artificiale risiede nella valutazione comparativa delle performance previsionali. Il parametro di riferimento più diffuso nella letteratura applicata rimane il *Mean Absolute Percentage Error* (MAPE), affiancato dalla *Root Mean Squared Error* (RMSE) per la quantificazione delle code di errore. Come consolidato nei capitoli precedenti, i metodi tradizionali si posizionano su un intervallo di riferimento che vede il MAPE oscillare tra il 12% e il 22%, a seconda del grado di sofisticazione dello strumento. Il confronto con i modelli di apprendimento automatico richiede una lettura più articolata, che tenga conto sia delle performance medie sia del comportamento dei modelli in condizioni di stress.

Una prospettiva d'insieme in questa direzione è offerta da Hewamalage, Bergmeir e Bandara (2021), che hanno condotto una revisione sistematica delle evidenze disponibili sull'applicazione del *deep learning* al forecasting di serie temporali, analizzando oltre cento dataset di natura eterogenea in differenti domini applicativi, incluse serie finanziarie e di flussi operativi. I risultati documentano che i modelli neurali ricorrenti, e in particolare le architetture LSTM, producono un vantaggio mediano sull'errore previsionale compreso tra il 15% e il 20% rispetto ai benchmark statistici locali (*local statistical benchmarks*), con un incremento del vantaggio proporzionale all'allungamento

dell'orizzonte di previsione. Gli autori osservano che tale superiorità non è uniforme. Infatti, le reti neurali globali, addestrate su dataset aggregati di serie multiple, mostrano performance particolarmente robuste in presenza di stagionalità complessa e di pattern di dipendenza non stazionari, mentre su serie brevi o statisticamente regolari il vantaggio tende a ridursi. Nel contesto del *cash management* aziendale, questa asimmetria di performance assume un impatto determinante. I flussi di cassa di una multinazionale, con stagionalità settoriali sovrapposte e dipendenze da variabili macroeconomiche eterogenee, rappresentano esattamente il dominio in cui il vantaggio delle architetture neurali si manifesta più nettamente.

Un contributo di particolare rilevanza per la tesoreria aziendale proviene dallo studio condotto da Morales-Resendiz et al. (2021), che hanno analizzato l'efficacia dei modelli di *machine learning* nella previsione degli incassi basata sulla singola fattura, invece di limitarsi a una stima generica del volume totale di cassa. Analizzando lo storico dei pagamenti e i termini contrattuali di ogni cliente, il sistema riesce a prevedere il momento esatto dell'incasso, trasformando una proiezione aggregata in una precisa cronologia finanziaria. L'impiego di architetture neurali e modelli di *gradient boosting* permette di catturare segnali che i metodi ARIMA classici tendono a ignorare, riducendo l'incertezza sulle date di incasso. La capacità di prevedere non soltanto l'ammontare degli incassi attesi, ma il loro esatto momento di realizzazione, consente al *cash manager* di ottimizzare le linee di credito *intraday* e di contrarre i periodi di eccesso precauzionale di liquidità, traducendosi in risparmi diretti sugli oneri finanziari a breve termine.

Un elemento critico che la sola analisi delle performance medie tende a oscurare riguarda il **comportamento dei modelli in condizioni di shock esogeno**. L'asimmetria delle performance previsionali durante eventi di discontinuità è stata documentata da Spiliotis, Makridakis, Semenoglou e Assimakopoulos (2022) attraverso l'analisi di un campione ampio di serie economico-finanziarie nel periodo che include la crisi pandemica del 2020. I risultati rivelano che i metodi di *machine learning*, e in particolare gli *ensemble* ibridi, mostrano una degradazione delle performance previsionali più contenuta rispetto ai modelli

ARIMA e allo *exponential smoothing* durante gli shock di regime. Si è notato che il MAPE dei metodi statistici classici si deteriora di un fattore compreso tra 1,8 e 2,4 volte rispetto al periodo pre-crisi, i modelli di apprendimento automatico mostrano un incremento dell'errore limitato a un fattore di 1,2–1,5 volte. Gli autori attribuiscono questa robustezza alla capacità dei modelli neurali di incorporare segnali anticipatori provenienti da variabili esogene, come indicatori di volatilità finanziaria e indici di *sentiment* economico, che agiscono come predittori precoci del cambiamento di regime prima che esso si manifesti nelle serie dei flussi operativi. Per la tesoreria aziendale, questa evidenza implica che il vantaggio comparativo dell'intelligenza artificiale è massimo esattamente nelle circostanze in cui una previsione affidabile è più critica.

3.3.2 *Efficienza operativa: Time to forecast e scalabilità*

L'accuratezza previsionale dei modelli rappresenta soltanto una dimensione del confronto tra i due paradigmi. La seconda dimensione riguarda **l'efficienza del processo di produzione** della previsione, ossia il tempo impiegato per raccogliere, normalizzare, elaborare e validare i dati, e la capacità del sistema di scalare orizzontalmente su un numero crescente di entità legali, conti bancari e valute senza un proporzionale incremento del carico operativo. In questa dimensione, il divario tra i metodi tradizionali e i sistemi basati sull'intelligenza artificiale è ancora più marcato, e si manifesta non soltanto in termini di efficienza interna ma di trasformazione strutturale del processo decisionale.

L'indagine condotta dal Capgemini Research Institute (2023) su oltre duecento funzioni di tesoreria di imprese europee con fatturato superiore a 500 milioni di euro, ha quantificato l'assorbimento di ore-uomo nei processi di *cash forecasting* tradizionali. I dati rivelano che nelle organizzazioni che non dispongono di automazione avanzata, il ciclo completo di produzione di un forecast settimanale richiede in media 14,3 ore-uomo, distribuite tra raccolta dati dai sistemi ERP e dalle business unit (5,8 ore), normalizzazione e riconciliazione dei flussi bancari (4,1 ore), elaborazione statistica e aggiustamento giudiziale (2,7 ore), e produzione della reportistica per il CFO (1,7 ore). Nelle organizzazioni che hanno implementato sistemi AI integrati con API bancarie in tempo reale, lo

stesso ciclo richiede in media 1,6 ore-uomo, con una riduzione dell'89% del tempo operativo. Il Capgemini osserva che la riduzione non è uniforme lungo le fasi del processo. La raccolta dati e la normalizzazione si riducono di oltre il 95% grazie all'automazione delle pipeline di integrazione, mentre la fase di revisione e validazione dell'output assorbe una quota proporzionalmente maggiore del tempo residuo, segnalando una riconfigurazione qualitativa del lavoro del *cash manager* verso attività di supervisione e interpretazione critica.

La dimensione della scalabilità emerge con particolare nitidezza nell'esperienza di Lenovo, documentata da Treasury Management International (2022). Il gruppo multinazionale cinese, aveva storicamente affidato il consolidamento della posizione di cassa globale a un processo manuale che richiedeva tra i tre e i cinque giorni lavorativi. L'implementazione di una piattaforma di *cash management* integrata con modelli di *machine learning* e API bancarie standardizzate ha ridotto il tempo di consolidamento a meno di trenta minuti, con un aggiornamento della posizione di liquidità su base oraria durante la giornata operativa. Il caso Lenovo illustra che i benefici dell'automazione basata su intelligenza artificiale non sono lineari rispetto alla complessità organizzativa, ma mostrano rendimenti crescenti al crescere del numero di entità da consolidare. Mentre il processo manuale subisce un degrado delle performance proporzionale alla complessità, il sistema automatizzato mantiene tempi di elaborazione sostanzialmente costanti indipendentemente dal numero di entità, eliminando la *scalability constraint* strutturale che aveva storicamente impedito il *cash forecasting* granulare nelle organizzazioni multinazionali.

Un caso complementare, documentato sempre da Treasury Management International (2023), riguarda British American Tobacco (BAT), che opera in oltre centottanta mercati con un'esposizione valutaria tra le più complesse nel comparto dei beni di largo consumo. La tesoreria di BAT aveva identificato nella gestione multi-currency il principale ostacolo alla qualità del *cash forecasting*. I tassi di cambio introducevano una fonte di varianza non modificabile attraverso modelli previsionali a singola variabile, rendendo inaffidabili le previsioni di cassa in valuta consolidata. Il passaggio a modelli di *machine learning* che incorporano in modo esplicito le curve di cambio forward, i differenziali di tasso

di interesse e la volatilità implicita dei mercati valutari come variabili esogene ha ridotto il MAPE delle previsioni consolidate in dollari del 34% rispetto al modello ARIMA a più variabili precedentemente adottato, con un abbattimento del *currency translation error* del 28%. BAT ha inoltre documentato una riduzione del numero di operazioni di copertura non pianificate, resisi necessari dai forecast errati, del 41% su base annua, con un risparmio diretto sulle commissioni di transazione stimato in circa 2,3 milioni di dollari annui.

3.3.3 Decisional Value: Dalla Previsione all'Azione

Il reale valore operativo del forecast non risiede nella sola precisione statistica in sé, ma nella qualità delle decisioni che abilita. Affinché il miglioramento previsionale, documentato nei paragrafi precedenti, si traduca in un'effettiva creazione del valore, la tesoreria deve poter agire lungo tre direttrici fondamentali: l'ottimizzazione delle **decisioni di funding**, la cattura di **opportunità di yield enhancement** sulle eccedenze di liquidità, e la **prevenzione degli eventi di financial distress** attraverso sistemi di allerta anticipata. L'analisi di questi tre dinamiche permette di completare il confronto tra i due paradigmi, portando la valutazione dal piano metrico a quello del valore economico generato.

Migliori decisioni di funding

Il rapporto tra accuratezza previsionale e costo del funding a breve termine opera attraverso un meccanismo diretto. Un forecast più accurato riduce l'incertezza sulla posizione di cassa futura, consentendo di dimensionare le linee di credito attivate in modo più preciso rispetto al fabbisogno effettivo. Nelle condizioni di previsione tradizionale, caratterizzate da MAPE superiori al 15%, il *cash manager* è incentivato a sovradimensionare il ricorso al *revolving credit* (credito rotativo), aggiungendo un margine di sicurezza che si traduce in *commitment fees* (commissioni di disponibilità) pagate su linee di credito parzialmente inutilizzate. L' European Association of Corporate Treasurers (2023) ha quantificato questo fenomeno su un campione di imprese europee di medie dimensioni riscontrando che, le organizzazioni con processi di forecasting

tradizionali pagano in media *commitment fees* equivalenti all'1,7% dell'ammontare accordato e inutilizzato, contro lo 0,9% delle organizzazioni dotate di sistemi AI. Su una linea di *revolving credit* da 50 milioni di euro con tasso di utilizzo medio del 60%, questa differenza si traduce in un risparmio annuo di circa 400.000 euro.

Oltre all'ottimizzazione degli importi, un ulteriore vantaggio economico scaturisce dall'estensione temporale delle previsioni. Lo studio condotto da Bharath, Pasquariello e Wu (2008), ha dimostrato come la riduzione dell'asimmetria informativa attraverso una gestione dei dati trasparente e affidabile influenzi direttamente il costo del debito bancario. I risultati documentano che le imprese capaci di generare informazioni finanziarie di alta qualità ottengono condizioni di accesso al credito sensibilmente migliori, poiché la precisione dei flussi attesi segnala una solida governance e riduce il premio per il rischio richiesto dai finanziatori. A conferma di questo schema teorico concorre l'esperienza della multinazionale Pearson, documentata da EuroFinance (2019). L'adozione di un sistema di *cash forecasting* potenziato dall'IA ha permesso alla tesoreria di estendere la visibilità sulla liquidità globale, portando a una riduzione dei finanziamenti a breve termine per 100 milioni di sterline. La maggiore accuratezza previsionale ha consentito di ottimizzare l'utilizzo delle linee di *revolving credit*, evitando il superamento delle soglie di utilizzo che avrebbero innescato, per clausola contrattuale, un incremento automatico dei margini di interesse sull'intera esposizione.

Cattura di opportunità di yield enhancement

L'eccesso di liquidità non investita rappresenta un costo opportunità che, nel contesto dei tassi di interesse post-2022, ha acquisito una rilevanza economica difficilmente trascurabile. In questo scenario, il report Global Liquidity PeerView di J.P. Morgan Asset Management (2023) evidenzia come una quota significativa della liquidità aziendale rimanga infruttiera (*idle cash*) su conti correnti non remunerati o scarsamente remunerati. Il principale driver di questa inefficienza è identificato nella persistente carenza di visibilità sui flussi di cassa a breve termine. L'incertezza sulla reale disponibilità di fondi nell'orizzonte

critico delle 48-72 ore spinge infatti i tesorerieri a mantenere riserve precauzionali eccessive per cautelarsi da eventuali shock. In assenza di un *forecast* affidabile, il *cash manager* si trova costretto a rinunciare a opportunità di investimento nel mercato monetario o a programmi di *yield enhancement*, subendo un costo opportunità (o *yield drag*) che penalizza direttamente la redditività del capitale investito.

L'impatto economico della precisione previsionale sulla gestione delle riserve trova una conferma operativa nel caso di Honeywell, documentato da EuroFinance (2020). La multinazionale ha intrapreso un percorso di trasformazione della tesoreria focalizzato sull'automazione del *cash forecasting* con l'obiettivo di ridurre la liquidità improduttiva. L'adozione di modelli predittivi avanzati ha permesso di estendere l'orizzonte di visibilità e di aumentare la confidenza nelle stime degli incassi, consentendo alla tesoreria di contrarre significativamente il cosiddetto margine di sicurezza (*safety cushion*) precedentemente mantenuto per far fronte a pagamenti imprevisti. Come rilevato dai responsabili della tesoreria del gruppo, una maggiore certezza nelle previsioni ha permesso di ridurre la quota di cassa non investita e di massimizzare le risorse disponibili per l'investimento in strumenti a rendimento positivo. Questo approccio ha generato da un lato, l'ottimizzazione del rendimento sul capitale altrimenti giacente; dall'altro, una maggiore disciplina nei centri finanziari del gruppo, che ha ridotto gli errori operativi e migliorato l'efficacia delle decisioni di allocazione della liquidità globale.

Un ulteriore vettore di *yield enhancement* (ottimizzazione dei rendimenti) è rappresentato dal ***dynamic discounting***, ovvero la pratica di anticipare i pagamenti ai fornitori in cambio di sconti commerciali proporzionali al periodo di anticipo. L'analisi aggregata su oltre duemila programmi di *dynamic discounting* attivi pubblicata da Taulia (2023), uno dei principali operatori nel mercato delle piattaforme di *supply chain finance*, nella sua analisi annuale sul *Working Capital*, evidenzia che le imprese dotate di sistemi di *cash forecasting* AI-driven riescono ad ottenere rendimenti privi di rischio superiori a quelli dei tradizionali strumenti del mercato monetario, con tassi di rendimento implicito che possono superare il 10% su base annua. Dal punto di vista operativo, tuttavia,

l'efficacia di questi programmi è strettamente subordinata alla qualità del *cash forecasting*. Ne consegue che, senza un *forecast* accurato a 30-60 giorni, il *cash manager* tende a rinunciare alla maggior parte delle opportunità di sconto in via precauzionale. Si stima che il rendimento implicito degli sconti dinamici conseguiti equivalga a un tasso annualizzato compreso tra il 6% e il 14%, significativamente superiore al rendimento degli strumenti di mercato monetario, rendendo la realizzazione di queste opportunità una delle leve di creazione di valore più rilevanti per la tesoreria nelle organizzazioni che dispongono di un forecast affidabile.

Gestione del rischio e tutela dei vincoli finanziari

Oltre all'ottimizzazione dei rendimenti, il valore strategico di un sistema previsionale avanzato si misura nella sua capacità di proteggere l'azienda dai rischi di liquidità. Da questo punto di vista, la sfida più complessa è la **prevenzione del *financial distress*** (tensione finanziaria) e, nello specifico, **evitare la violazione dei vincoli finanziari**. Tali clausole impongono all'impresa il mantenimento di saldi minimi di cassa o di indici di copertura del debito al di sopra di soglie predefinite. La loro inosservanza non si limita a produrre sanzioni contrattuali, ma innesca processi di rinegoziazione del debito che, nelle fasi di mercato avverse, possono tradursi in costi di funding permanentemente più elevati e in un deterioramento delle relazioni bancarie di lungo periodo.

Nell'analisi pubblicata sul *Journal of Financial*, i ricercatori Chodorow-Reich e Falato (2022) hanno documentato, su un campione ampio di prestiti bancari, che circa un terzo dei contratti di credito analizzati registra una violazione di vincoli finanziari nel biennio 2008–2009, e che tale violazione attiva un meccanismo secondo la quale, la banca finanziatrice riduce la disponibilità di linee di credito e aggrava le condizioni contrattuali, generando un razionamento del credito con effetti reali sull'investimento e sull'occupazione dell'impresa debitrice. Tradotto nella prospettiva della tesoreria aziendale, il vincolo finanziario non si limita a produrre costi diretti di rinegoziazione, ma innesca un deterioramento strutturale delle condizioni di funding che può persistere per diversi trimestri successivi

all'evento. In questo contesto, lo sviluppo di **sistemi di *early warning*** fondati su architetture di *deep learning* rappresenta la risposta tecnologica più efficace per monitorare la solvibilità in tempo reale. Come analizzato da Gunnarsson et al. (2021), l'impiego di reti neurali profonde permette di rilevare segnali deboli di tensione finanziaria con un'accuratezza superiore ai modelli statistici classici, fornendo al tesoriere il margine temporale necessario per attivare leve correttive, quali la rimodulazione dei pagamenti o l'ottimizzazione del circolante, prima che si verifichi la violazione dei vincoli contrattuali. Un'evidenza operativa di questo approccio è offerta dall'esperienza di AstraZeneca⁵⁸, che ha implementato modelli di *machine learning* per centralizzare la visibilità sui flussi globali e prevedere con precisione i fabbisogni di liquidità, neutralizzando il rischio di scoperti tecnici e garantendo la piena aderenza ai parametri di rischio del gruppo. Sul piano degli strumenti di prevenzione, lo studio da Mai *et al.* (2019), pubblicato sullo *European Journal of Operational Research*, ha applicato modelli di *deep learning* alla previsione del rischio di tensione finanziaria. I risultati documentano che le reti neurali raggiungono un'accuratezza predittiva superiore rispetto ai modelli logistici tradizionali. La chiave di questo vantaggio si manifesta soprattutto nella capacità del *deep learning* di rilevare dinamiche di deterioramento anticipato non lineari, come la compressione progressiva dei margini di copertura del debito in combinazione con un peggioramento del ciclo di conversione della cassa, che i modelli lineari tendono a segnalare soltanto quando la tensione è già parzialmente manifestata. Nelle applicazioni di tesoreria aziendale, questa capacità di rilevazione anticipata consente di attivare misure correttive, quali l'accelerazione degli incassi, la compressione delle uscite discrezionali o l'attivazione preventiva di linee di credito di emergenza, in una finestra temporale sufficiente a evitare l'inosservanza dei vincoli finanziari. La validità operativa di questo impianto teorico trova riscontro nell'esperienza di Microsoft Treasury. Il processo di digitalizzazione della multinazionale è stato analizzato nel report ufficiale pubblicato dalla Association for Financial Professionals⁵⁹ all'interno della AFP Guide to Emerging Technologies in

⁵⁸ EuroFinance, 2022

⁵⁹ AFP, 2019

Treasury, e analiticamente corroborato dallo studio di White et al. (2019) sull'architettura algoritmica di Microsoft Finance. Gestendo flussi di cassa per decine di miliardi di dollari distribuiti su molteplici giurisdizioni, l'azienda registrava inefficienze legate a marcate deviazioni previsionali (*variance*), che esponevano la tesoreria a improvvisi fabbisogni di cassa. L'implementazione di un modello di machine learning ha permesso alla tesoreria di superare i limiti dell'analisi lineare, istruendo l'algoritmo a riconoscere i cicli storici di incassi e pagamenti. Questa transizione ha garantito un miglioramento dell'accuratezza predittiva del 30% rispetto ai preesistenti modelli statistici. Tale precisione algoritmica ha consentito di decifrare le dinamiche di cassa con largo anticipo, neutralizzando gli episodi di deficit imprevisti. Disporre di questa visibilità estesa ha garantito a Microsoft il margine temporale necessario per ottimizzare i trasferimenti intragruppo e disinnescare le tensioni di liquidità prima che potessero manifestarsi, evitando del tutto il ricorso a costosi strumenti di copertura d'emergenza e scongiurando il rischio di deterioramento delle relazioni bancarie.

Alla luce delle evidenze analizzate, emerge chiaramente come il valore dell'intelligenza artificiale non si limiti a una semplice rifinitura statistica delle previsioni, ma si materializza in una catena di effetti economici misurabili che si estendono dall'ottimizzazione del costo del funding alla cattura di opportunità di rendimento altrimenti inaccessibili, fino alla prevenzione di eventi di tensione finanziaria i cui costi diretti e indiretti superano spesso in modo il costo complessivo di adozione e gestione delle soluzioni tecnologiche. Poiché le inefficienze dei metodi tradizionali sono profonde e radicate, tentare di colmarle con semplici aggiustamenti marginali risulta ormai anacronistico. Per gestire la complessità della tesoreria moderna è necessaria una vera e propria discontinuità tecnologica, adeguata alla complessità operativa della tesoreria aziendale moderna.

CONCLUSIONE

La letteratura osserva che l'integrazione dell'Intelligenza Artificiale nel cash management rappresenta senza dubbio una trasformazione categorica per la tesoreria d'impresa, capace di superare i limiti strutturali dei metodi di previsione tradizionali. Per le organizzazioni in grado di sostenerne l'implementazione, si è osservato come l'adozione di architetture di Machine e Deep Learning, come XGBoost e reti LSTM, garantisce una drastica riduzione dell'errore previsionale, abbattendo il MAPE a soglie comprese tra il 3% e il 9%. Supportata dall'integrazione in tempo reale tramite API bancarie, questa eccellenza algoritmica genera vantaggi finanziari tangibili: ottimizza il Capitale Circolante Netto, riduce le *commitment fees* sulle linee di credito e abilita rendimenti extra tramite pratiche di *yield enhancement* come il *dynamic discounting*. Tali modelli, inoltre, agiscono come fondamentali sistemi di *early warning*, proteggendo l'azienda dal rischio di tensioni finanziarie e scongiurando la violazione dei vincoli contrattuali.

Nonostante ciò, l'entusiasmo per tali potenzialità deve confrontarsi con severe barriere all'ingresso, che rendono l'adozione massiva particolarmente complessa per le Piccole e Medie Imprese (PMI). I costi di implementazione e i canoni delle piattaforme SaaS presentano una struttura fissa che richiede significative economie di scala; in assenza di un elevato volume di transazioni, l'incidenza di tali costi comprime il ritorno sull'investimento (ROI), rendendo spesso preferibile un approccio incrementale. A questo limite dimensionale si sommano ingenti costi occulti legati all'architettura informatica, che rappresentano la principale causa di sfioramento dei budget. Inoltre, vige il rigoroso principio del *garbage in, garbage out*: l'efficacia predittiva è subordinata alla pulizia dei dati storici, condizione che arriva ad assorbire fino al 40% del tempo e delle risorse progettuali. Infine, la transizione tecnologica pone complessi ostacoli organizzativi e strategici, come *automation anxiety* nei team di tesoreria, l'elevato rischio di *vendor lock-in* tipico delle piattaforme in cloud, e la necessità di continui riaddestramenti algoritmici per prevenire il fisiologico degrado delle performance, noto come *concept drift*. In sintesi, l'Intelligenza Artificiale applicata alla tesoreria non costituisce una soluzione tecnologica

immediatamente risolutiva, indipendente dal contesto in cui viene inserita. Affinché l'investimento risulti realmente sostenibile, la delibera della direzione finanziaria impone un'accurata valutazione preventiva della propria maturità informatica, della qualità dei dati a disposizione e dell'effettiva propensione organizzativa al cambiamento.

BIBLIOGRAFIA

- Accenture (2023). Total Enterprise Reinvention: The Financial Strategy of AI Adoption. Accenture Strategy & Consulting Report.
- ACFE - Association of Certified Fraud Examiners (2022). Occupational Fraud 2022: A Report to the Nations.
- AFP - Association for Financial Professionals (2024). AFP Digital Shift: AI and Automation in Corporate Treasury. AFP Survey & Research.
- AFP (2019). AFP Guide to Emerging Technologies in Treasury. Association for Financial Professionals.
- Aldasoro, I., & Desai, R. (2025). AI agents for cash management in payment systems. Bank of Canada Staff Working Paper 2025-35.
- Armstrong, J. S. (2001). Principles of forecasting: A handbook for researchers and practitioners. Springer.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Benetot, A., & García, S. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115.
- Athanasopoulos, G., Hyndman, R. J., Kourentzes, N., & Petropoulos, F. (2017). Forecasting with temporal hierarchies. *European Journal of Operational Research*, 262(1)
- Bank for International Settlements & Financial Stability Board (2023). Regulating AI in the financial sector: Recent developments and main challenges. FSI Insights No. 63.
- Barney, J. B. (1991). Firm Resources and Sustained Competitive Advantage. *Journal of Management*, 17(1), 99-120.
- Bates, T. W., Kahle, K. M., & Stulz, R. M. (2009). Why do US firms hold so much more cash than they used to? *The Journal of Finance*, 64(5).
- Bech, M. L., & Hobijn, B. (2007). Technology diffusion within central banking: The case of real-time gross settlement. *International Journal of Central Banking*, 3(3).
- Bergmeir, C., & Benítez, J. M. (2012). Neural networks in R using the Stuttgart Neural Network Simulator: RSNNS. *Journal of Statistical Software*, 46(7).
- Bharadwaj, A., El Sawy, O. A., Pavlou, P. A., & Venkatraman, N. (2013). Digital business strategy: Toward a next generation of insights. *MIS Quarterly*, 37(2).
- Bharath, S. T., Pasquariello, P., & Wu, G. (2009). Does Asymmetric Information Drive

Capital Structure Decisions? *Review of Financial Studies*, 22(8).

Box, G. E. P., & Jenkins, G. M. (1970). *Time Series Analysis: Forecasting and Control*. Holden-Day.

Bragg, S. M. (2010). *Treasury Management: The Practitioner's Guide*. John Wiley & Sons.

Brealey, R. A., Myers, S. C., & Allen, F. (2015). *Principles of Corporate Finance* (11th ed.). McGraw-Hill Education.

Brown, R. G. (1959). *Statistical Forecasting for Inventory Control*. McGraw-Hill.

Brynjolfsson, E., & Hitt, L. M. (1996). Paradox lost? Firm-level evidence on the returns to information systems spending. *Management Science*, 42(4).

Capgemini Research Institute. (2023). *World Treasury Report 2023: Reimagining Treasury in the Age of AI*. Capgemini

Chatfield, C. (1978). The Holt-Winters forecasting procedure. *Journal of the Royal Statistical Society*.

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.

Chen, Yi-Chi and Yu, Wei-Choun, *The Housing Price Forecasting and the Outbreak of the Financial Crisis: Evidence of the Arima Model* (May 17, 2010).

Deloitte. (2022). *Global Treasury Survey 2022*.

Chodorow-Reich, G., & Falato, A. (2022). The loan covenant channel: How bank health transmits to the real economy. *The Journal of Finance*, 77(1).

Citigroup (2025). *Treasury and Trade Solutions: The Future of Real-Time Liquidity and AI-Driven Automation*. Citi GPS: Global Perspectives & Solutions.

Clements, M. P., & Harvey, D. I. (2011). Combining probability forecasts. *International Journal of Forecasting*, 27(2), 208–223.

Copeland, T., & Antikarov, V. (2001). *Real Options: A Practitioner's Guide*. Texere.

Davenport, T. H., & Ronanki, R. (2018). Artificial Intelligence for the Real World. *Harvard Business Review*, 96(1), 108-116.

Davern, M. J., & Kauffman, R. J. (2000). Discovering potential and realizing value from information technology investments. *Journal of Management Information Systems*, 16(4).

Dechow, N., & Mouritsen, J. (2005). Enterprise resource planning systems, management control and the quest for integration. *Accounting, Organizations and Society*.

Deloitte (2023). Crunch time series: Finance in a digital world. Deloitte Insights / Deloitte Development LLC.

Deloitte. (2022). Global Treasury Survey 2022.

Deloitte (2024). CFO Signals: Digital Transformation and the Evolving Role of the Cash Manager. Deloitte Insights.

Deloitte (2024). Treasury technology and AI adoption survey: Finance workforce transformation. Deloitte Advisory.

Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. (2016). Deep Direct Reinforcement Learning for Financial Signal Representation and Trading. *IEEE Transactions on Neural Networks and Learning Systems*, 28(3), 653-664.

Deutsche Bank (2022). Case study: Deutsche Bahn - Staying one step ahead of payment fraud. *flow magazine*.

Deutsche Bank. (2023). Has cashflow forecast become obsolete

Dixit, A. K., & Pindyck, R. S. (1994). *Investment under Uncertainty*. Princeton University Press.

EACT – European Association of Corporate Treasurers (2023). Liquidity and Funding Survey: How AI-Driven Forecasting Is Reshaping Credit Line Management. EACT.

ERP Software Blog (2025). Dynamic Cash Positioning with AI-Powered Treasury in ERP Software Blog (2025). Dynamic Cash Positioning with AI-Powered Treasury in Dynamics 365 Finance.

EuroFinance (2019). Case study: Pearson's award-winning treasury transformation. EuroFinance Treasury Excellence Awards. EuroFinance Treasury Excellence Awards.

EuroFinance (2020). Honeywell's AI-free cash forecasting robots: Maximising cash available for investment and saving time. EuroFinance Case Study Series.

EuroFinance (2021). Perfecting virtual account management with an in-house bank: The Roche Case Study. Case Study Series.

EuroFinance (2022). AstraZeneca: Forecasting with precision. EuroFinance Case Study Series / Treasury Excellence Awards.

EuroFinance. (2022). Logitech Treasury Transformation: Extending Forecast Horizons with AI. EuroFinance Conference Proceedings 2022.

Fichman, R. G., Keil, M., & Tiwana, A. (2005). Beyond valuation: "Options thinking" in IT project management. *California Management Review*, 47(2).

Fitranita, et al. (2024). Predicting Future Cash Flows Using Autoregressive Integrated Moving Average (ARIMA), *EKOMBIS REVIEW Jurnal Ilmiah Ekonomi dan Bisnis*.

Forrester Research (2023). The Total Economic Impact[™] (TEI) of AI-Driven Cash Management Solutions. Forrester Consulting.

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5).

Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys*, 46(4), 44:1–44:37.

Gartner (2023). CFO and Finance Leader Survey: AI in Treasury Operations. Gartner Research.

Gartner (2023). CFO and Finance Leader Survey: Cost Overruns in AI Implementations. Gartner Research.

Gartner (2024). Predicts 2024: The Future of Finance Operations and AI Monetization. Gartner Research.

Gartner. (2023). CFO and Finance Leader Survey: Cost Overruns in AI Implementations. Gartner Research.

Giacalone, M., Mattera, R., & Nissi, E. (2021). Machine learning forecasting of financial series: Comparison of gradient boosting models and ARIMA. *Journal of Risk and Financial Management*, 14(11), 516.

Gitman, L. J. (1974). Estimating corporate liquidity requirements: A simplified approach. *The Financial Review*, 9(1).

Glaum, M., Schmidt, P., & Schnürer, M. (2018). Processes and Accuracy of Cash Flow Forecasting: A Case Study of a Multinational Corporation. *Journal of Applied Corporate Finance*.

Goldman Sachs Asset Management. (2023). Liquidity Pulse: Corporate Cash Holdings and the Cost of Underinvestment in European Money Markets. GSAM Liquidity Solutions.

Gunnarsson, B. R., vanden Broucke, S., Baesens, B., Óskarsdóttir, M., & Lemahieu, W. (2021). Deep learning for financial distress prediction. *Journal of the Operational Research Society*, 72(10), 2200-2212.

Henderson, J. C., & Venkatraman, N. (1993). Strategic alignment: Leveraging information technology for transforming organizations. *IBM Systems Journal*, 32(1).

Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388–427.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.

Holt, C. C. (1957). Forecasting trends and seasonals by exponentially weighted moving averages.

HSBC Global Banking (2025). Real-time treasury: Smarter liquidity, stronger control and quicker decision-making. HSBC Business Insights

HSBC Global Banking (2025). The Open Banking Revolution: Integrating APIs in Modern Corporate Treasury. HSBC Global Liquidity Report.

Hyndman, R. J., & Athanasopoulos, G. (2021). Forecasting: Principles and Practice (3rd ed.), OTexts.

IBM Data & AI Economics (2024). The true cost of data preparation in Enterprise AI. IBM Institute for Business Value.

J.P. Morgan Asset Management (2023). Global Liquidity PeerView: Navigating the path back to yield. J.P. Morgan Insights.

Kahneman, D., & Tversky, A. (1974). Judgment under uncertainty: Heuristics and biases. *Science*, 185(4157).

Karaev, Alan et al. (2022): A comparative analysis of the choice of mother wavelet functions affecting the accuracy of forecasts of daily balances in the treasury single account, *Economies*, ISSN 2227-7099, MDPI, Basel, Vol. 10, Iss. 9, pp. 1-27

Keynes, J. M. (1936). *The General Theory of Employment, Interest and Money*. Macmillan.

Kingma, S., Leguizamo, A., & Bricco, L (2024). Cash forecasting: Difficult, disappointing and more urgent than ever

Kirwin, B., & Livingston, J. (1987). Total Cost of Ownership: A Framework for IT Investments. Gartner Group. (Nota: Questa Ã¨ la fonte storica fondamentale che ha coniato il termine TCO).

KPMG (2024). *The Future of Corporate Treasury: Accelerating Digital Transformation*. KPMG International.

Kyriba (2023). Spotify's Journey to Treasury Automation and Real-Time Cash Visibility. Treasury Transformation Case Study.

Lavalle, S., Lesser, E., Shockley, R., Hopkins, M. S., & Kruschwitz, N. (2011). Big data, analytics and the path from insights to value. *MIT Sloan Management Review*, 52(2).

Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200209.

Mai, F., Tian, S., Lee, C., & Ma, L. (2019). "Deep learning models for bankruptcy prediction using textual disclosures". *European Journal of Operational Research*,

274(2), 743-758.

Makridakis, S., et al. (1982). The M-competition: Results, conclusions and implications. *Journal of Forecasting*.

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, 13(3)

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1).

McKinsey & Company (2024). The economic potential of generative AI: The next productivity frontier in Corporate Finance. McKinsey Global Institute.

McKinsey & Company (2024). The new CFO mandate: Next-generation finance operating models. McKinsey Global Institute.

McKinsey & Company. (2021). How transaction banks are reinventing treasury services

Michael Lawrence, Paul Goodwin, Marcus O'Connor & Önköl, D. (2006), Judgmental forecasting: A review of progress over the last 25 years, *International Journal of Forecasting*, Volume 22, Issue 3, Pages 493-518

Milgrom, P., & Roberts, J. (1990). The economics of modern manufacturing: Technology, strategy, and organization. *American Economic Review*, 80(3).

Mooney, J. G., Gurbaxani, V., & Kraemer, K. L. (1996). A Process-Oriented Framework for Assessing the Business Value of Information Technology. *The Journal of Strategic Information Systems*, 5(2), 117-141.

MuleSoft (2024). Connectivity Benchmark Report: Overcoming Integration Challenges in the Enterprise. Salesforce/MuleSoft.

Nocco, B. W., & Stulz, R. M. (2006). Enterprise Risk Management: Theory and Practice. *Journal of Applied Corporate Finance*, 18(4), 8-20.

Oliver Wyman. (2023). Treasury technology in European corporates: Benchmark report. Oliver Wyman Financial Services.

Opler, T., Pinkowitz, L., Stulz, R., & Williamson, R. (1999). The determinants and implications of corporate cash holdings. *Journal of Financial Economics*, 52(1).

Orlikowski, W. J. (2000). Using Technology and Constituting Structures: A Practice Lens for Studying Technology in Organizations. *Organization Science*, 11(4), 404-428.

Pang, Y., Shi, S., Shi, Y. et al. A nonlinear dynamic approach to cash flow forecasting. *Rev Quant Finan Acc* 59, (2022).

Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., & Boylan, J. E. et al. (2022). Forecasting:

Theory and practice. *International Journal of Forecasting*, 38(3), 705–871.

Pinkowitz, L., Stulz, R. M., & Williamson, R. (2016). Do US firms hold more cash than foreign firms do? *The Review of Financial Studies*, 29(2).

Polak, P., Robertson, D. C., & Lind, M. (2011). The new role of the corporate treasurer: Emerging trends in response to the financial crisis. *International Research Journal of Finance and Economics*, 78, 48–69.

Prosci (2023). *Best Practices in Change Management (12th Edition)*. Prosci Benchmarking Report.

PwC - PricewaterhouseCoopers (2024). *Global Treasury Survey: Treasury's role in driving sustainable value*. PwC Network Report.

PwC. (2025). *Global Treasury Survey 2025*

PwC (2023). *Global Digital Treasury Survey: Navigating the implementation of AI and automation*. PwC Network.

PYMNTS.com (2025, November). *Agentic AI puts a face on corporate treasury's next leap*.

Ransbotham, S., Kiron, D., & Prentice, P. K. (2016). Beyond the Hype: The Hard Work Behind Analytics Success. *MIT Sloan Management Review*, 57(3).

Redman, T. C. (2008). *Data driven: Profiting from your most important business asset*. Harvard Business Review Press.

REL Consultancy (2022). *Working Capital Performance Scorecard: The 6% Revenue Differential*. REL Global Research.

Sagner, J. S. (2014). *Cash Management: A Practitioner's Guide*. John Wiley & Sons.

Seifert, R. W., & Seifert, D. (2011). Financing the Chain. *International Commerce Review*, 10(1), 32-44.

Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2018). A comparison of ARIMA and LSTM in forecasting time series. *Proceedings of the 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*.

Siemens AG / Deutsche Bank (2025). *Treasury in real time – Siemens case*. Deutsche Bank Flow Magazine.

Soprano, A., Crielaard, B., Paci, F., & Lannoo, D. (2009). *Measuring operational and reputational risk: A practitioner's approach*. John Wiley & Sons.

Spiliotis, E., Makridakis, S., Semenov, A.-A., & Assimakopoulos, V. (2022). Comparison of statistical and machine learning methods for daily SKU demand forecasting. *Operational Research*, 22(3).

Suharsono, et al. (2022). *Modelling and forecasting cash outflow-inflow using ARIMA-*

Feedforward Neural Network

Taulia (2023). 2023 Working Capital Survey: High interest rates and inflation drive the need for liquidity. Taulia / SAP Insights.

Teece, D. J. (2018). Business models and dynamic capabilities. *Long Range Planning*, 51(1).

The Hackett Group (2023). Working Capital Survey: Unlocking Cash from Operations through Predictive Analytics. The Hackett Group Performance Studies.

Timmermann, A. (2006). Forecast combinations. In G. Elliott, C. W. J. Granger, & A. Timmermann (Eds.), *Handbook of Economic Forecasting* (Vol. 1). Elsevier.

Treasury Intelligence Solutions (2025). How agentic AI is transforming treasury.

Treasury Management International TMI. (2022). *Lenovo Treasury Transformation: From Multi-Day Consolidation to Real-Time Global Cash Positioning*. TMI Case Study Series.

Tsymbol, A. (2004). The problem of concept drift: Definitions and related work (Technical Report TCD-CS-2004-15). Department of Computer Science, Trinity College Dublin.

U.S. Department of the Treasury (2024). Report on the uses, opportunities, and risks of artificial intelligence in financial services. White Paper.

Weill, P., & Ross, J. W. (2004). *IT Governance: How Top Performers Manage IT Decision Rights for Superior Results*. Harvard Business School Press.

White, R. W., et al. (2019). Curriculum Learning in Deep Neural Networks for Financial Forecasting.