



Università  
Ca' Foscari  
Venezia

Laurea Magistrale in  
Amministrazione Finanza e Controllo

Tesi di Laurea

**Big Data e frode contabile.  
Analisi strutturata della letteratura e  
raffronto tra modelli di previsione della  
frode.**

**Relatore**

Ch. Prof.ssa Marisa Agostini

**Laureanda**

Cristina Cancian

Matricola 856726

**Anno Accademico**

2019/2020



## **RINGRAZIAMENTI**

*In primis, un ringraziamento speciale alla mia relatrice Marisa Agostini, per la sua immensa pazienza, per i suoi indispensabili consigli, per la sua infinita disponibilità e tempestività ad ogni mia richiesta*

*Ringrazio infinitamente la mia famiglia, i miei genitori Maria Teresa e Valter e mia sorella Ilenia che mi hanno sempre sostenuto, appoggiando ogni mia decisione, fin dalla scelta del mio percorso di studi.*

*Un grazie al mio ragazzo Manuel per aver sempre creduto in me, avermi incoraggiato nei momenti di difficoltà ed aver gioito insieme a me nei momenti belli.*

*Grazie ai miei compagni di università, con i quali ci siamo sempre sostenuti a vicenda, nella buona e nella cattiva sorte, sia durante le fatiche e lo sconforto del nostro percorso, che nei momenti di gioia e soddisfazione.*

*Un ringraziamento alle mie Amiche di una vita, che ogni giorno hanno condiviso con me gioie, sacrifici e successi, senza voltarmi mai le spalle.*



# INDICE

<b>INTRODUZIONE .....</b>	<b>5</b>
<b>Capitolo 1 INDAGINE BIBLIOGRAFICA.....</b>	<b>9</b>
1.1 Metodologia di ricerca .....	9
1.2. Analisi e risultati ottenuti.....	10
1.3 Impatto dell'articolo .....	17
1.4 Definizione del quadro analitico .....	18
<b>Capitolo 2 Aree e domande di ricerca .....</b>	<b>25</b>
2.1 Determinazione delle aree di ricerca.....	25
2.2 Domande di ricerca.....	31
<b>Capitolo 3 Risultato e analisi di ricerca .....</b>	<b>35</b>
3.1. <i>Accounting</i> : Il ruolo del contabile nella prevenzione della frode con i <i>Big Data</i> .....	35
3.1.1. Il rapporto esistente tra l' <i>Accounting</i> e i <i>Big Data</i> .....	35
3.1.2. Utilizzo dei <i>Big Data</i> per la rilevazione di frode in ambito contabile.....	37
3.1.3 Osservazioni finali <i>Big Data</i> e frode in ambito contabile.....	45
3.2 <i>Auditing</i> : l'utilizzo dei <i>Big Data</i> per la rilevazione di frodi in ambito di revisione .....	46
3.2.1 Utilizzo dei <i>Big Data</i> in ambito di revisione.....	46
3.2.2 <i>Big Data</i> e rilevazione della frode nel campo della revisione.....	49
3.2.3 Osservazioni finali relative ai <i>Big Data</i> e frode nella revisione .....	64
3.3 <i>Models</i> : strumenti di <i>Big Data</i> utilizzati per la rilevazione della frode.....	65
3.3.1 Caratteristiche dei modelli di <i>Big Data</i> .....	65
3.3.2 Modelli di <i>Big Data</i> applicati per rilevare la frode.....	69
3.3.3 Osservazioni finali sui modelli di <i>Big Data</i> applicati per rilevare la frode.....	92
<b>Capitolo 4 Confronto tra modelli di previsione della frode .....</b>	<b>93</b>
4.1 Modelli utilizzati per il confronto.....	95
4.1.1 Introduzione al modello Dechow et al.....	95
4.1.2 Introduzione al modello Cecchini et al.....	96
4.1.3 Introduzione al modello apprendimento d'insieme .....	97
4.2 Metriche di valutazione delle prestazioni.....	98

4.2.1	Metrica AUC .....	98
4.2.2	Metrica NDCG@ K.....	100
4.3.	Il campione .....	103
4.3.1.	Periodo del campione.....	103
4.3.2.	Il campione .....	105
4.3.3	Utilizzo dei dati finanziari grezzi .....	107
4.4	Risultati dei modelli selezionati.....	112
4.4.1	Modello Dechow et al. ....	112
4.4.2	Modello di Cecchini et al. ....	113
4.4.3.	Modello apprendimento d'insieme .....	115
4.4.3.1	Metodo modello di regressione logistica con dati finanziari grezzi .....	116
4.4.3.2	Metodo apprendimento d'insieme con dati finanziari grezzi .....	116
4.4.3.3	Rapporti finanziari e dati grezzi utilizzando il metodo di apprendimento d'insieme .....	118
4.4.3.4	Metodo di apprendimento d'insieme con maggiori dati finanziari grezzi .....	119
4.4.3.5	Criticità del metodo di apprendimento d'insieme.....	120
4.5	Considerazioni finali.....	123
	<b>CONCLUSIONE .....</b>	<b>127</b>
	<b>BIBLIOGRAFIA .....</b>	<b>129</b>
	<b>SITOGRAFIA.....</b>	<b>146</b>

## INTRODUZIONE

*Big Data* e frode contabile è un argomento molto attuale ma allo stesso tempo poco diffuso, nonostante l'importanza dei tempi attuali.

Per iniziare è apprezzabile analizzare i due fenomeni separatamente, in modo da definire cosa si intende per *Big Data* e per frode.

Il termine *Big Data* indica genericamente una raccolta di dati informativi, estesa in termini di volume, velocità e varietà tanto da richiedere tecnologie e metodi analitici specifici per l'estrazione di valore.

Per poter parlare di *Big Data* il volume dei dati deve essere correlato alla capacità del sistema di acquisire le informazioni così come arrivano dalle differenti sorgenti dati che sono adoperate, quindi, un sistema diventa *Big* quando aumenta il volume dei dati e allo stesso tempo aumenta la velocità/flusso di informazioni che il sistema deve poter acquisire e gestire per secondo.

Non esiste una soglia di riferimento, in termini di dimensione, oltre la quale si può definire *Big Data*: in genere si parla di *Big Data* quando l'insieme di dati è talmente grande e complesso che richiede la definizione di nuovi strumenti e metodologie per estrapolare, gestire e processare informazioni entro un tempo ragionevole.

Le tre caratteristiche principali che possono definire i *Big Data*, sono le seguenti:

- Volume: indica la quantità di dati (strutturati o non strutturati) generati ogni secondo da sorgenti quali logaritmi, email, social media e database tradizionali;
- Varietà: indica la differente tipologia di dati che vengono generati, analizzati e utilizzati. Oltre ai classici dati strutturati che venivano presi in considerazione già prima dell'avvento dei *Big Data*, per avere analisi più accurate e più profonde, è necessario prendere in considerazione anche:
  - o a) dati non strutturati (ad esempio file di testo generati dalle macchine industriali);
  - o b) dati semi strutturati (ad esempio un atto notarile con frasi fisse e frasi variabili);
- Velocità: indica la velocità con cui i dati vengono generati.



Figura 1: Le V dei Big Data.

(Fonte: E. Ferroni, Novembre 2016 “Una nuova sfida per l’epidemiologia. Un uso responsabile dei big data che generi conoscenza e migliori la salute”- Forward)

Sono state inoltre introdotte altre due V, veridicità e valore:

- **Veridicità:** considerando la varietà dei dati e la velocità è molto probabile che non si riesca a garantire la stessa qualità di dati di input ai sistemi di analisi come quelli disponibile nei processi tradizionali. È importante sottolineare che se i dati alla base delle analisi sono poco accurati, i risultati delle analisi non saranno corretti e visto che su tali risultati possono essere basate delle decisioni, è fondamentale assegnare un indice di veridicità.
- **Valore:** indica la capacità di trasformare i dati in valore. Un progetto *Big Data* necessita investimenti, anche importanti, per la raccolta dei dati e la loro analisi, perciò è importante valutare e documentare quale sia il valore effettivo portato al business.

Per frode invece si intende un reato che consiste nella falsificazione delle comunicazioni sociali, manipolando le informazioni presenti all’interno dei documenti che compongono il bilancio d’esercizio.

Il falso in bilancio può essere di tre tipi:



- Oggettivo, quando ci sono, all'interno di un bilancio, una complessità di dati e informazioni non vere ad esempio omissione di costi o ricavi più alti della realtà;
- Valutativo, quando l'incongruenza riguarda le valutazioni aziendali ad esempio, stime immobiliari o valutazioni di marchi e brevetti;
- Qualitativo, quando intacca le voci di bilancio stesse e il modo in cui vengono presentate all'interno dei documenti ad esempio l'utilizzo di fondi in modo illecito, catalogandoli come una spesa lecita.

I due fenomeni messi assieme costituiscono un argomento del tutto nuovo e ancora da scoprire, per questo nei capitoli successivi si andrà ad analizzare l'introduzione dei *Big Data* per la previsione, prevenzione e rilevazione della frode attraverso un'analisi strutturata della letteratura. In particolare nel capitolo 1 viene riprodotta e analizzata tutta la procedura di identificazione degli articoli utilizzati per la bibliografia strutturata, scaricati dal database *Scopus*, mediante una chiave di ricerca definita e delle limitazioni imposte al fine di individuare documenti inerenti all'argomento. Nel capitolo 2 sono stati suddivisi tutti gli articoli selezionati in 3 aree di ricerca, definite in base alla predominanza del tema trattato da essi. In seguito per ciascun'area sono state individuate le domande di ricerca pertinenti. Nel capitolo 3 sono state esplicitate le risposte alle domande individuate nel capitolo precedente, mediante l'utilizzo degli articoli selezionati. Infine nel capitolo 4 è stato esposto il confronto tra 3 modelli di previsione della frode. In particolare si è voluto verificare se un nuovo modello, mai analizzato (apprendimento d'insieme) fosse superiore come prestazioni a due modelli (Cecchini et al 2010, Dechow et al. 2011) già in precedenza analizzati dalla letteratura.



## Capitolo 1 INDAGINE BIBLIOGRAFICA

Per affrontare questa analisi usiamo la metodologia della revisione strutturata della letteratura poiché il tema “*Big Data* e frode contabile” è un concetto relativamente nuovo.

Per offrire approfondimenti e critiche che valutano, identificano e affrontano possibili programmi di ricerca futuri, si adotta il metodo Structured literature review (SLR): “*An SLR is a method for studying a corpus of scholarly literature, to develop insights, critical reflections, future research paths and research questions*” (Massaro et al., 2016, p. 2); cioè si intende un metodo, per studiare un insieme di documenti accademici, con lo scopo di approfondire e riflettere in maniera critica, in modo da poter creare percorsi e domande di ricerca inerenti ad un argomento poco sviluppato o emergente.

La diversità delle fonti in letteratura ha portato alla necessità di una metodologia sistematica per definire le teorie e i modelli correlati ad un fenomeno; pertanto la Structured Literature Review (SLR) può essere considerata come un mezzo attraverso il quale la letteratura centrale e quella alla base della ricerca può essere mappata.

Come sottolineano Petty e Guthrie (2000), ci sono due obiettivi principali per effettuare un indagine relativa ad un campo emergente. In primo luogo, è necessario “*categorise it in a way that provides a useful understanding of how and why the movement has developed in the way it has*” cioè analizzare come il fenomeno di cui ci si sta occupando si sia sviluppato e in secondo luogo “*a platform to identify those avenues for future research that we consider likely to deliver results for understanding the nature, impact and value*” (Petty, Guthrie, 2000, p. 156) ovvero individuare la ricerca futura più attinente per comprendere la natura, l'impatto e il valore del fenomeno analizzato. Pertanto, l'obiettivo è quello di seguire questi punti e fornire una giustificazione empirica per le domande di ricerca che si delineano e le successive risposte.

### 1.1 Metodologia di ricerca

Per dare inizio allo sviluppo del tema è stata svolta un'attività di ricerca bibliografia attraverso l'utilizzo di “*Scopus Preview*”, database di riassunti e citazioni per articoli di pubblicazioni riguardanti la ricerca.

Per prima cosa sono stati individuati dei sinonimi pertinenti ai termini della nostra ricerca “*Big Data and accounting fraud*”, identificando come sinonimo di “*Big Data*”

*analytics* e *macro data* di *accounting*, *bookkeeping* e di *fraud*, *misstatement*, *deceit*, *cheating* e *swindle*.

È stato quindi possibile creare la chiave di ricerca da immettere nel database *Scopus*, di seguito indicata.

*“Big Data” OR analytics OR “macro data” AND accounting OR bookkeeping AND fraud OR misstatement OR deceit OR cheating OR swindle*

In particolare è stata utilizzata la funzione “advanced” tanto da espandere la ricerca a tutti gli articoli presenti nel database che contengono le parole della chiave e, non limitando ai soli articoli contenenti le parole nel titolo, negli *abstract* e nelle parole chiave.

In seguito a questa prima ricerca sono stati inseriti altri criteri di selezione per identificare esclusivamente articoli pertinenti.

Sono stati selezionati solo articoli attraverso la funzione “*document type: articles*”, stampati o in stampa cioè già accettati dalle riviste per la pubblicazione ma non ancora assegnati ad un numero, attraverso la funzione “*source type: journals*”, solo scritti in lingua inglese (*language: English*) e infine considerando solo documenti dell’area “*Business, Management and Accounting*” in quanto è quella più attinente allo studio e la più popolare, mediante la funzione “*subject area*”.

Nel paragrafo successivo saranno illustrati i risultati ottenuti tramite questa metodologia.

## **1.2. Analisi e risultati ottenuti**

In seguito all’immissione della chiave di ricerca sopra citata (“*Big Data*” *OR analytics OR “macro data” AND accounting OR bookkeeping AND fraud OR misstatement OR deceit OR cheating OR swindle*) sono stati individuati 1087 documenti. A questo punto sono state applicate le limitazioni indicate nel precedente paragrafo.

Il primo è di considerare solo articoli attraverso la funzione “*document type: articles*” ottenendo 660 documenti. In seguito sono stati considerati solo gli articoli stampati o in stampa attraverso la funzione “*source type: journals*” e sono rimasti 654 articoli. Per proseguire è stato necessario considerare solo articoli scritti in lingua inglese, solo 3 risultano scritti in altra lingua. L’ultimo criterio di selezione si riferisce all’area tematica, considerando solo documenti dell’area “*Business, Management and Accounting*” in quanto è quella più attinente allo studio e la più popolare (Tabella 1).

<b>Area tematica</b>	<b>N° documenti su Scopus</b>
Business Management and Accounting	355
Computer Science	136
Decision Science	103

Tabella 1. Le 3 aree tematiche più significative. (Fonte: personale, dati estratti da Scopus)

Prendendo in considerazione solamente l'area tematica "Business Management and Accounting" vengono selezionati 355 articoli. Questi ultimi sono stati pubblicati in 156 riviste ("*source title*") (Tabella2).

<b>Titolo della rivista</b>	<b>N° di articoli</b>
International Journal Of Accounting Information Systems	20
Journal Of Emerging Technologies In Accounting	18
Journal Of Information Systems	14
Managerial Auditing Journal	13
Accounting Horizons	12
Journal Of Accounting Education	9
Journal Of Accounting Research	8
Decision Support Systems	7
Academy Of Accounting And Financial Studies Journal	6
Journal Of Accounting Literature	6
Journal Of Business Ethics	6
Journal Of Management Information Systems	6
Accounting Review	5
British Accounting Review	5
Intelligent Systems In Accounting Finance And Management	5
International Journal Of Accounting And Information Management	5
International Journal Of Digital Accounting	5

Research	
Technological Forecasting And Social Change	5
Accounting Organizations And Society	4
Auditing	4
Critical Perspectives On Accounting	4
Issues In Accounting Education	4
Journal Of Business Research	4
Knowledge Based Systems	4

Tabella 2. Riviste che hanno pubblicato il maggior numero di articoli. (Fonte: personale, dati estratti da Scopus)

Dopo aver compiuto tutte le limitazioni, aver individuato l'area tematica e le riviste con il maggior numero di articoli, è possibile considerare le parole chiavi maggiormente presenti nei 355 articoli.

La principale e più considerata è "*Big Data*" con 42 contributi, in quanto elemento fondamentale della ricerca, sono presenti poi "*Big Analytics*" (23) in quanto indicato come sinonimo di *Big Data* e "*Fraud*" (17) parola fondamentale della nostra ricerca. A queste si aggiungono poi "*Artificial intelligence*" (19), "*Machine Learning*" (17), "*Auditing*" (13) e "*Risk Management*" (12). Nell'analisi condotta vengono considerati tutti gli anni, anche il 2020 ed è possibile notare che il maggior numero di pubblicazioni sono avvenute dal 2015 ad oggi, in quanto negli anni precedenti questo argomento non era molto esaminato e quindi sono presenti pochi contributi (Tabella3).

Anno	N° di articoli selezionati in Scopus
2020	38
2019	102
2018	71
2017	46
2016	25
2015	23
2014	19
2013	14
2012	5
2011	2

2010	4
2009	1
2008	1
2006	3
2004	1
1988	1

Tabella 3. Anno di pubblicazione degli articoli selezionati in Scopus. (Fonte: personale, dati estratti da Scopus)

Dopo questa attenta analisi ed una prima riduzione degli articoli, si è ritenuto necessario effettuare un'ulteriore limitazione in quanto non tutti gli articoli erano effettivamente pertinenti con la ricerca. Si è proseguito analizzando tutti i 355 documenti nella lettura del titolo, dell'*abstract* e in alcuni casi, non essendo sufficiente questa analisi, è stata esaminata l'introduzione, in modo da avere più chiara la trattazione dell'articolo. Con questo metodo i 355 articoli sono stati ridotti a 36.

Questa notevole riduzione è avvenuta in quanto molti articoli trattano il tema "*Big Data*" in generale ma non toccano in maniera approfondita l'argomento della frode collegata con i *Big Data*, per questo motivo è stato deciso di eliminarli e non utilizzarli per l'analisi bibliografica. Quelli considerati invece approfondiscono il tema "*Big Data and fraud*", per questo è stato deciso di includerli.

Di seguito si riportano i 36 documenti selezionati per l'analisi (Tabella 4)

	<b>TITOLO</b>	<b>AUTORE</b>	<b>ANNO</b>
1	A data warehouse design for the detection of fraud in the supply chain by using the Benford's law	Kraus C., Valverde R.	2014
2	An accounting information systems perspective on data analytics and Big Data	Huerta E., Jensen S.	2017
3	Analytical procedures in external auditing: A comprehensive literature survey and framework for external audit analytics	Appelbaum D.A., Kogan A., Vasarhelyi M.A.	2018
4	Automated clustering for data analytics	Byrnes P.E.	2019

5	Behavioral implications of Big Data's impact on audit judgment and decision making and future research directions	Brown-Liburud H., Issa H., Lombardi D.	2015
6	Big Data analytics in financial statement audits	Cao M., Chychyla R., Stewart T.	2015
7	Big Data and changes in audit technology: contemplating a research agenda	Salijeni G., Samsonova-Taddei A., Turley S.	2019
8	Big Data as complementary audit evidence	Yoon K., Hoogduin L., Zhang L.	2015
9	Big Data techniques in auditing research and practice: Current trends and future opportunities	Gepp A., Linnenluecke M.K., O'Neill T.J., Smith T.	2018
10	Data analytics in auditing: Opportunities and challenges	Earley C.E.	2015
11	Data mining applications in accounting: A review of the literature and organizing framework	Amani F.A., Fadlalla A.M.	2017
12	Data visualization for fraud detection: Practice implications and a call for future research	Dilla W.N., Raschke R.L.	2015
13	Designing audit apps for armchair auditors to analyze government procurement contracts	Dai J., Li Q.	2016
14	Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach	Bao Y., Ke B., Li B., Yu Y.J., Zhang J.	2020
15	Detecting manager's fraud risk using text analysis: evidence from Iran	Rahrovi Dastjerdi A., Foroghi D., Kiani G.H.	2019



16	Development of algorithms for searching, analyzing and detecting fraudulent activities in the financial sphere	Khrestina M.P., Dorofeev D.I., Kachurina P.A., Usubaliev T.R., Dobrotvorskiy A.S.	2017
17	Digital systems and new challenges of financial management – Fin Tech, XBRL, Blockchain and Cryptocurrencies	Mosteanu N.R., Faccia A.	2020
18	Eight issues on audit data analytics we would like researched	Wang, T., Cuthbertson R.	2015
19	Embracing textual data analytics in auditing with deep learning	Sun T., Vasarhelyi M.A.	2018
20	Financial fraud detection and Big Data analytics – implications on auditors’ use of fraud brainstorming session	Tang J., Karim K.E.	2019
21	How Big Data will change accounting	Warren J.D., Moffitt K.C., Byrnes P.	2015
22	Impacts of digitization on auditing: A Delphi study for Germany	Tiberius V., Hirth S.	2019
23	Incorporating Big Data in audits: Identifying inhibitors and a research agenda to address those inhibitors	Alles M., Gray G.L.	2016
24	Interactive visual analysis of anomalous accounts payable transactions in SAP enterprise systems	Singh K., Best P.	2016
25	Leveraging Financial Social Media Data for Corporate Fraud Detection	Dong W., Liao S., Zhang Z.	2018
26	Manual journal entry testing: Data analytics and the risk of fraud	Fay R., Negangard E.M.	2017

27	Motivation to use Big Data and Big Data analytics in external auditing	Dagilienė L., Klovienė L.	2019
28	Multidimensional audit data selection (MADS): A framework for using data analytics in the audit data selection process	No W.G., Lee K., Huang F., Li Q.	2019
29	Mystery, Inc.: A Big Data case	Enget K., Saucedo G.D., Wright N.S.	2017
30	Protecting a new Achilles heel: the role of auditors within the practice of data protection	La Torre M., Botes V.L., Dumay J., Odendaal E.	2019
31	Relevance of Big Data to forensic accounting practice and education	Rezaee Z., Wang J.	2019
32	Researches of detection of fraudulent financial statements based on data mining	Han D.	2017
33	Text mining using latent semantic analysis: An illustration through examination of 30 years of research at JIS	Guan J., Levitan A.S., Goyal S.	2018
34	The role of internet-related technologies in shaping the work of accountants: New directions for accounting research	Moll J., Yigitbasioglu O.	2019
35	Using generalized audit software to detect material misstatements, control deficiencies and fraud: How financial and IT auditors net audit benefits	Bradford M., Henderson D., Baxter R.J., Navarro P.	2020
36	When should audit firms introduce analyses of Big Data into the audit process?	Rose A.M., Rose J.M., Sanderson K.-A., Thibodeau J.C.	2017

Tabella 4. Documenti selezionati secondo il titolo, l'abstract e le parole chiavi. (Fonte: personale, dati estratti da Scopus)

### 1.3 Impatto dell'articolo

Procedendo con il lavoro di bibliografia strutturata si verifica l'impatto degli articoli all'interno della letteratura in base al numero di citazioni accademiche. Per fare ciò, si recuperano direttamente dal database *Scopus* i dati delle citazioni, raccolte dal 1996 in poi, per ciascun articolo. La tabella mostra i primi dieci articoli secondo il numero di citazioni (Tabella 5).

	<b>TITOLO</b>	<b>AUTORE</b>	<b>FONTE</b>	<b>ANNO</b>	<b>CITAZIONI</b>
1	Behavioral implications of Big Data's impact on audit judgment and decision making and future research directions	Brown-Liburud, H., Issa, H., Lombardi, D.	Accounting Horizons, 29	2015	69
2	Big Data analytics in financial statement audits	Cao, M., Chychyla, R., Stewart, T.	Accounting Horizons, 29	2015	68
3	How Big Data will change accounting	Warren, J.D., Moffitt, K.C., Byrnes, P.	Accounting Horizons, 29	2015	65
4	Big Data as complementary audit evidence	Yoon, K., Hoogduin, L., Zhang, L.	Accounting Horizons, 29	2015	48
5	Big Data techniques in auditing research and practice: Current trends and future opportunities	Gepp, A., Linnenluecke, M.K., O'Neill, T.J., Smith, T.	Journal of Accounting Literature, 40	2018	28
6	Data visualization for fraud detection: Practice implications	Dilla, W.N., Raschke, R.L.	International Journal of Accounting	2015	21

	and a call for future research		Information Systems, 16,		
7	Data mining applications in accounting: A review of the literature and organizing framework	Amani, F.A., Fadlalla, A.M.	International Journal of Accounting Information Systems, 24	2017	20
8	Data analytics in auditing: Opportunities and challenges	Earley, C.E.	Business Horizons, 58	2015	16
9	Leveraging Financial Social Media Data for Corporate Fraud Detection	Dong, W., Liao, S., Zhang, Z.	Journal of Management Information Systems, 35	2018	14
10	Analytical procedures in external auditing: A comprehensive literature survey and framework for external audit analytics	Appelbaum, D.A., Kogan, A., Vasarhelyi, M.A.	Journal of Accounting Literature, 40	2018	11

Citazioni aggiornate al 18-04-2020

Tabella 5. Articoli selezionati in ordine di citazioni. (Fonte: personale, dati estratti da Scopus)

#### **1.4 Definizione del quadro analitico**

Al fine di condurre una buona analisi e seguire tutte le fasi di analisi, gli analisti sono incoraggiati a utilizzare un quadro analitico. Le strutture analitiche sono progettate per strutturare il pensiero di un analista e per aiutare il pensiero logico in modo sistematico. In breve, i quadri analitici sono modelli che mirano a guidare e facilitare il rilevamento e la comprensione dei fenomeni analizzati.

L'analisi del quadro analitico qui sviluppato applica i criteri in precedenza utilizzati da Guthrie et al. (2012) e Dumay e Garanina (2013) che hanno proseguito la loro analisi

sulla base dei criteri adottati da Petty e Guthrie (2000) nell'analisi del medesimo campo di ricerca; si tratta di un quadro analitico derivato da precedenti revisioni dal quale è possibile suggerire l'adozione, l'aggiunta o l'eliminazione di criteri in base alle tematiche trattate negli articoli in esame.

Vengono utilizzati questi criteri in quanto permettono al ricercatore di espandere i confini della ricerca in letteratura e potenzialmente sviluppare percorsi e domande di ricerca più pertinenti e mirate, inoltre consente di organizzare la letteratura esistente in maniera adeguata al tema trattato.

Durante la codifica è stato necessario modificare e aggiungere i criteri o attributi in modo da renderli idonei alla selezione degli articoli; in particolare è stata inserita la sezione G in quanto la codificazione originale non considerava la tipologia degli articoli selezionati.

La codificazione è stata così sviluppata:

- ✓ A Jurisdiction
  - A1 Sovranazionale/Internazionale/Comparativo-Generale;
    - A1.1 Sovranazionale/Internazionale/Comparativo-Industriale;
    - A1.2 Sovranazionale/Internazionale/Comparativo- Organizzativo.
  - A2 Nazionale-Generale;
    - A2.1 Nazionale-Industriale;
    - A2.2 Nazionale-Organizzativo.
  - A3 Organizzazione specifica.
- ✓ B Organizational Focus;
  - B1 Organizzazione quotate in borsa;
  - B2 Privato – PMI;
  - B3 Privato – Altri;
  - B4 Settore pubblico;
  - B5 No profit;
  - B6 Altro.
- ✓ C Country of research;
  - C1 America;
  - C2 Australasia;
  - C3 Regno Unito;
  - C4 Unione Europea;

- C5 Altro.
- ✓ D Focus of Literature;
  - D1 Rapporti con l'estero;
  - D2 Revisione;
  - D3 Responsabilità e governance;
  - D4 Controllo di gestione/ Strategia;
  - D5 Misurazione/valutazione delle prestazioni;
  - D6 Altro.
- ✓ E Research methods criterion;
  - E1 Caso / studio sul campo/ intervista;
  - E2 Analisi contenuto / Storica;
  - E3 Questionario / Sondaggio / Altro empirico.
- ✓ F Frameworks and models;
  - F1 Nessun proposto;
  - F2 Applica o considera il precedente;
  - F3 Propone nuovo modello.
- ✓ G Type of article;
  - G1 Academics;
  - G2 Practitioners and consultants;
  - G3 Academics, practitioners and consultants.

Si sviluppano di seguito tutti i singoli criteri applicati al caso preso in considerazione.

**Il primo criterio analizzato è *jurisdiction* (A)** cioè l'ambito di competenza, suddiviso nei seguenti criteri:

- A1 Sovranazionale/Internazionale/Comparativo-Generale;
  - A1.1 Sovranazionale/Internazionale/Comparativo-Industriale;
  - A1.2 Sovranazionale/Internazionale/Comparativo- Organizzativo.
- A2 Nazionale-Generale;
  - A2.1 Nazionale-Industriale;
  - A2.2 Nazionale-Organizzativo.
- A3 Organizzazione specifica.

Permette di individuare articoli che non hanno una base empirica (A1), articoli che si concentrano su nazioni e territori specifici (A2) e infine documenti che fanno riferimento a un contesto organizzativo specifico (A1.1; A1.2; A2.1; A2.2; e A3).

La categoria più popolare è la prima, Sovranazionale/Internazionale/Comparativo-Generale (A1), cioè documenti che non hanno una base empirica in quanto trattano il tema a livello generale e non riferito né ad una specifica regione né ad una singola organizzazione, (ad esempio *Huerta, Jensen 2017* tratta il tema dei *Big Data* dal punto di vista contabile, senza far riferimento ad una specifica organizzazione e tanto meno ad una singola regione- *Early 2015 – Wang, Cuthbertson 2015* si occupano dell'utilizzo dei *Big Data* in campo di auditing delineando opportunità e sfide a livello generale). Segue la categoria Nazionale-Generale (A2) cioè articoli che si concentrano su nazioni o regioni specifiche.

In seguito troviamo le sottocategorie, che fanno riferimento ad un contesto organizzativo ovvero: A1.1 sovrnazionale/interazionale/comparativo-industria che comprende documenti basati su settori specifici appartenenti a paesi specifici, A1.2 sovrnazionale/interazionale/comparativo-organizzativo che include documenti che fanno riferimento ad una o più organizzazioni appartenenti a più settori o più paesi; A2.1 nazionale-industriale, che comprende articoli basati su un settore specifico appartenente a un singolo paese (ad esempio *Tiberius, Hirth 2019* che tratta il tema di *auditing* in Germania) e infine A2.2, nazionale-organizzativo cioè organizzazioni appartenenti a un singolo paese. Si classificano infine articoli che fanno riferimento a una particolare organizzazione specifica come A3 ma in questo caso non sono presenti documenti.

Si può notare che la maggior parte degli articoli adotta un approccio sovrnazionale/internazionale/comparativo a livello generale in quanto, l'argomento trattato è maggiormente sviluppato senza far riferimento ad una specifica area o ad un territorio e senza riferirsi ad una specifica organizzazione; solo 5 articoli analizzano il fenomeno facendo riferimento ad un settore specifico appartenente a un singolo paese (A2.1 esempio *Rezaee, Wang 2019* il quale fa riferimento all'utilizzo dei *Big Data* in contabilità forense in Cina).

**Il secondo criterio è *Organizational Focus (B)*** che individua su quale tipo di organizzazione si concentra l'articolo; è costituito da sei attributi:

- B1: organizzazioni quotate in borsa;
- B2: privato - PMI;
- B3: privato - Altri;
- B4: settore pubblico;

- B5: no profit;
- B6: generale / Altro.

Lo studio rileva che le organizzazioni maggiormente considerate sono nella categoria B6 cioè “altro” in quanto si parla molto di *Big Data and fraud* a livello generale cioè della contabilità delle aziende in generale oppure dell’attività di revisione e non riferito a singole e specifiche organizzazioni. Ci sono comunque articoli che trattano del settore pubblico (3) in particolare sui servizi in generale o delle banche, residuali invece sono il settore privato e le organizzazioni quotate in borsa.

**Il criterio *Country of research* (C)** è il terzo dello schema di classificazione qui adottato e si occupa di attribuire un paese specifico al documento nel quale viene svolta la ricerca; nel momento in cui non fosse possibile determinare il focus regionale o la posizione geografica della ricerca, viene utilizzato il paese del primo autore.

È necessario rivedere gli attributi di questa categoria in modo da adattarli agli articoli selezionati. Viene cambiata “Nord America” in America in generale e “Europa continentale” in Unione Europea (UE).

Il Paese di ricerca o le caratteristiche del primo autore sono divisi in sei regioni:

- C1: America;
- C2: Australasia che comprende Australia, Nuova Zelanda e alcune isole dell’oceano Pacifico;
- C3: Regno Unito, compresi Inghilterra, Irlanda, Scozia e Galles;
- C4: Unione Europea ;
- C5: altro.

La regione più attiva è la zona dell’America con 21 articoli in quanto è un paese molto sviluppato a livello tecnologico che già in anni passati ha affrontato l’argomento (ad esempio, *Bradford, Henderson, Baxter, Navarro 2020* i quali sono tutti ricercatori degli USA– *Fay, Negangard 2017* anche in questo caso i ricercatori sono degli USA); a questa seguono le categorie “altro” e “Unione Europea”.

**Il quarto criterio è *Focus of Literature* (D)** cioè su quale argomento si è concentrato lo sviluppo dell’articolo. Si classificano le categorie come segue:

- D1: reporting esterno;
- D2: revisione contabile;
- D3: responsabilità e governance;
- D4: controllo/strategia di gestione;



- D5: misurazione/valutazione delle prestazioni;
- D6: altro (nel caso in cui non fosse possibile codificare gli articoli con i primi cinque attributi, si utilizza un attributo generico).

Le due categorie più popolari sono: misurazione/valutazione delle prestazioni e revisione contabile. La prima è molto popolare in quanto molti articoli trattano veri e propri sistemi di *Big Data* utilizzati per rilevare la frode e quindi misurano la prestazione che il sistema ha; mentre la seconda è molto ricercata in quanto l'attività di revisione risulta oggi sempre più sviluppata ma non sempre vengono utilizzati sistemi di *Big Data* per facilitarne il suo svolgimento.

**Il criterio *Research methods criterion* (E)** definisce il metodo di ricerca utilizzato per sostenere la tesi alla base dei diversi articoli cioè come vengono raccolti i dati al fine di argomentare la tesi dei diversi documenti. Include cinque attributi, i primi tre riguardano studi di natura empirica, essendo:

- E1: caso / studio sul campo / interviste (ad esempio *No, Lee, Huang, Li 2019* dove viene applicato sul campo un metodo studiato per l'aiuto dell'auditing - *Tiberius, Hirth 2019* i quali esaminano i cambiamenti nelle pratiche di auditing attesi dai professionisti tedeschi nei prossimi cinque o dieci anni. - *Gepp, Linnenluecke, O'Neill, Smith 2018* anche loro studiano i cambiamenti e le opportunità in tema di auditing);
- E2: analisi del contenuto/storica;
- E3: questionario / sondaggio / altro empirico (ad esempio *Rezaee, Wang 2019* utilizzano un sondaggio tra accademici e professionisti per verificare la rilevanza dei *Big Data* in contabilità forense).

I successivi due attributi sono di natura normativa e includono:

- commenti / normativo / politico (E4);
- revisione della letteratura (E5) (ad esempio: *Moll, Yigitbasioglu* esaminano la letteratura contabile concentrata su quattro tecnologie relative a Internet che hanno il potenziale per cambiare radicalmente e interrompere il lavoro dei contabili e dei ricercatori contabili nel prossimo futuro...).

I risultati mostrano che il metodo di ricerca più comunemente impiegato è caso / studio sul campo / interviste, seguito da questionario / sondaggio / altro empirico e revisione della letteratura con 2 contenuti ciascuno.

**Il successivo criterio è *Frameworks and models (F)*** cioè considera il fatto che il documento includa modelli, proponendone di nuovi o riprendendone alcuni già utilizzati. Si codificano gli articoli come:

- Nessuno proposto (F1 ad esempio *Cao, Chychyla, Stewart 2015* i quali spiegano come le analisi dei *Big Data* applicate in altri domini potrebbero essere applicate nel controllo);
- Applica o considera il precedente (F2 ad esempio *Enget, Saucedo, Wright 2017* i quali introducono due fasi una di pianificazione dei *Big Data* e l'altra di analisi dei risultati – *Dai, Li 2016* i quali progettano app utilizzate in sede di audit per scovare frodi);
- Propone un nuovo (F3 ad esempio *Guan, Levitan, Goyal 2018* introducono l'analisi semantica latente (LSA), un approccio di estrazione del testo che scopre strutture latenti in dati testuali non strutturati, utilizzata negli ultimi 30 anni- *No, Lee, Huang, Li 2019* che introducono il multidimensional audit data selection ovvero MADS...).

La maggior parte degli articoli non propone nessun modello ma buona parte di essi considera un modello precedente mentre in piccola parte ne propongono di nuovi (4 contributi).

Per concludere l'analisi è necessario inserire **il criterio *Type of article (G)*** in modo da considerare chi tra accademici, professionisti e consulenti ha apportato il contributo alla letteratura. Codifichiamo articoli scritti da:

- Academics, (G1 ad esempio *Brown-Liburd, Issa, Lombardi 2015* i quali sono tutti assistenti professori di Università degli Stati Uniti – *Guan, Levitan, Goyal 2018* accademici dell'università di Louisville);
- Practitioners and consultants (G2 ad esempio *Warren, Moffitt, Byrnes 2015* dei quali 2 sono assistenti professori, l'altro è uno studioso del settore);
- Academics, practitioners and consultants (G3).

Con queste categorie si verifica se l'articolo è stato scritto da soli accademici, da professionisti insieme a consulenti oppure da accademici con professionisti e consulenti. La maggior parte sono scritti da accademici (34), solo due sono scritti da consulenti e professionisti mentre dell'ultima categoria non sono presenti contributi.

## Capitolo 2 Aree e domande di ricerca

Nel presente capitolo si andrà a: individuare le tre aree di ricerca su cui sviluppare lo studio, suddividere gli articoli nelle tre aree individuate, identificare le domande di ricerca relative a ciascuna area.

In particolare mediante la lettura dei titoli, delle parole chiave, dell'*abstract* e ove necessario dell'introduzione e/o l'intero articolo, sono state individuate le tre aree di ricerca.

In seguito sono state identificate le domande di ricerca più pertinenti a ciascuna categoria, alle quali si andrà a rispondere nel capitolo successivo.

Questo passaggio è uno dei motivi per cui si sviluppa una *Structured Literature Review* cioè individuare delle domande di ricerca inerenti al tema trattato alle quali si risponderà mediante una bibliografia selezionata con uno specifico criterio esposto nel Capitolo 1.

### 2.1 Determinazione delle aree di ricerca

Dopo aver individuato e codificato gli articoli utili alla ricerca, è stato necessario suddividerli in diverse aree al fine di identificare le domande di ricerca specifiche per ogni area oggetto di analisi.

Le aree sono state individuate in base alla prospettiva con cui i documenti selezionati affrontano il tema, analizzando i titoli, l'*abstract* e le parole chiave di ciascuno, se necessario sono stati letti l'introduzione e/o l'intero articolo. È stato possibile inoltre correlare le parole chiave individuate in precedenza con le aree identificate.

La prima area individuata si occupa dell'utilizzo dei *Big Data* in ambito contabile; quest'area è stata individuata poiché sono presenti articoli che espongono il fenomeno dei *Big Data* utilizzati in ambito contabile.

Si tratta di un mercato ancora di nicchia ma promettente che permette ai contabili di avere una nuova opportunità, senza subire cambiamenti radicali, consentendo di aggiungere un ruolo nuovo alla figura del commercialista o esperto contabile, proprio quel professionista che già oggi tutti i giorni ha a che fare con una mole enorme di dati e numeri provenienti da Pmi, attività artigianali fino a società individuali.

La comunità imprenditoriale e la professione contabile dovrebbero trarre vantaggio dall'opportunità offerta dai *Big Data* di analisi dei dati, nel migliorare l'efficacia e l'efficienza del loro lavoro.

Individuando quest'area si vuole approfondire la possibilità di distorsione dei sistemi informativi, poiché sono molto utilizzati per questo tipo di attività e sono sì utili ma allo stesso tempo possono creare problemi.

A tal proposito mediante l'utilizzo dei *Big Data*, diverse fonti di dati vengono integrate nei sistemi di informazione contabile. Ad esempio, i dati di testo, video e audio vengono gradualmente collegati ai dati tradizionali. I contabili devono migliorare le proprie capacità di analisi dei dati per far fronte a grandi volumi di dati disponibili, compresi quelli estratti automaticamente (come quelli acquisiti da parte dei clienti) e allo stesso tempo devono conoscere meglio la sicurezza informatica poiché i dati commercialmente sensibili nel cloud sono vulnerabili agli attacchi informatici e ciò crea grandi preoccupazioni.

I *Big Data* e l'analisi dei dati influenzeranno la contabilità in molti modi condizionando la maniera in cui sono pilotati gli affari e il modo in cui i bilanci vengono preparati e controllati. A tal proposito in fase di chiusura del bilancio il commercialista deve verificare la presenza dell'eventuale frode e anche per questa fase possono essere molto utili i *Big Data*, in quanto aiutano il professionista in questo delicato e complesso momento.

In quest'area inoltre, è possibile approfondire il miglioramento della qualità e la pertinenza delle informazioni contabili e la funzione dei professionisti (commercialisti) nella rilevazione della frode.

La parola chiave a cui si può ricondurre quest'area è "*risk management*" ovvero gestione del rischio cioè l'insieme di attività, metodologie e risorse coordinate per guidare e tenere sotto controllo un'organizzazione con riferimento ai rischi da parte del contabile.

La seconda tratta il tema della revisione legale in quanto, compito basilare del revisore è quello di rilevare l'eventuale frode. A tal proposito l'attività di *auditing*, in questi ultimi mesi, ha avuto un rilievo ancora maggiore grazie all'introduzione dell'obbligo di revisione anche per le nano imprese; a ciò è stato, in molti casi, necessario introdurre sistemi di supporto all'attività.

È importante anche rilevare come nel campo della revisione spesso non sia stato adottato nessun strumento che aiuti l'attività ma si basi tutto sulla sola esperienza del revisore o della società di revisione.

È fondamentale quindi individuare come l'attività di revisione sia cambiata con l'introduzione dei *Big Data* ma soprattutto come i revisori possono individuare, con questi mezzi, eventuali frodi all'interno delle aziende che vanno a revisionare.

I revisori si trovano ora ad affrontare la sfida di enormi quantità di dati strutturati (ad esempio contabilità generale o dati di transazione) e non strutturati (ad esempio campi di posta elettronica, voce o testo libero in un database, sensori Wi-Fi, etichette elettroniche, ecc.), da elaborare insieme con una quantità crescente di dati tradizionali (ad esempio elenchi di controllo di terze parti, mezzi di informazione, descrizioni di pagamenti a testo libero, comunicazioni e-mail e social media). I revisori utilizzano i *Big Data* perché devono essere in grado di seguire come i loro clienti gestiscono i propri *Big Data*, ma allo stesso tempo possono utilizzarli per ridurre i costi dei loro audit e migliorare la redditività.

Confirmation.com (piattaforma che offre conferme digitali per revisori, banchieri, responsabili del credito e personale delle risorse umane) fornisce un esempio di conferma di audit automatizzata. La società fornisce servizi di conferma di audit sicuri per oltre 14.000 società di revisione contabile, 100.000 revisori contabili e 700.000 organizzazioni. Descrive il suo servizio come una soluzione all-in-one (cioè tutto in un'unica piattaforma) che aiuta a ridurre al minimo le frodi e ad aumentare l'efficienza per l'intero processo di conferma dell'audit. Con i *Big Data*, i revisori possono analizzare sia i dati strutturati che quelli non strutturati per identificare potenziali anomalie transazionali (ad esempio erogazioni non autorizzate), modelli di comportamento (ad esempio pagamenti divisi per aggirare il limite di transazione) e tendenze (ad esempio aumento delle transazioni fraudolente), come conseguenza dell'utilizzo della raccolta automatica dei dati e di tecniche di analisi basate su regole, per identificare gli errori.

La parola correlata a quest'area è "*auditing*" ovvero revisione che rappresenta in tutti i sensi l'area individuata.

Infine l'ultima area è caratterizzata da documenti che identificano dei modelli di *Big Data* utili ed efficaci per l'individuazione e la gestione della frode. Quest'area è stata individuata in quanto molti articoli sviluppano dei sistemi di raccolta dati che alle volte sono necessari per l'individuazione della frode ma allo stesso tempo, possono provocare loro stessi frodi.

Il volume di dati dei *Big Data* e l'ampio uso di dati non strutturati non permette l'utilizzo dei tradizionali sistemi per la gestione di dati relazionali (RDBMS<sup>1</sup>), se non attraverso tecniche di strutturazione del dato. Un dato strutturato archiviato nei tradizionali sistemi RDBMS permette di avere prestazioni infinitamente migliori, nella ricerca, rispetto ai sistemi NoSQL<sup>2</sup> assicurando la consistenza del dato, che in sistemi *Big Data* generalmente non è garantita.

In base agli strumenti e ai modelli utilizzati per l'analisi e la gestione dei dati è possibile distinguere quattro metodologie (o tipologie) di *Big Data Analytics*:

- *Descriptive Analytics*: insieme di strumenti orientati a descrivere la situazione attuale e passata dei processi aziendali e/o aree funzionali. Tali strumenti permettono di accedere ai dati in maniera interattiva (inserendo ad esempio filtri) e di visualizzare in modo sintetico e grafico i principali indicatori di prestazione (è utilizzata dalle grandi organizzazioni);
- *Predictive Analytics*: basata su soluzioni che permettono di eseguire l'analisi dei dati al fine di disegnare scenari di sviluppo nel futuro. Le Predictive Analytics si basano su modelli e tecniche matematiche come i Modelli Predittivi, il Forecasting e altri;
- *Prescriptive Analytics*: strumenti che associano l'analisi dei dati alla capacità di assumere e gestire processi decisionali. Le Prescriptive Analytics sono strumenti che mettono a disposizione delle indicazioni strategiche o delle soluzioni operative basate sia sull'Analisi Descrittiva sia sulle Analisi Predittive;

---

<sup>1</sup> Un sistema di gestione di database relazionali (RDBMS) è un programma che consente di creare, aggiornare e amministrare un database relazionale. La maggior parte dei sistemi di gestione di database relazionali utilizza il linguaggio SQL (cioè è un linguaggio di programmazione utilizzato per comunicare con i dati archiviati in un sistema di gestione di database relazionale) per accedere al database.

<sup>2</sup> È un movimento che promuove sistemi software dove la persistenza dei dati è in generale caratterizzata dal fatto di non utilizzare il modello relazionale, di solito usato dalle basi di dati tradizionali (RDBMS)

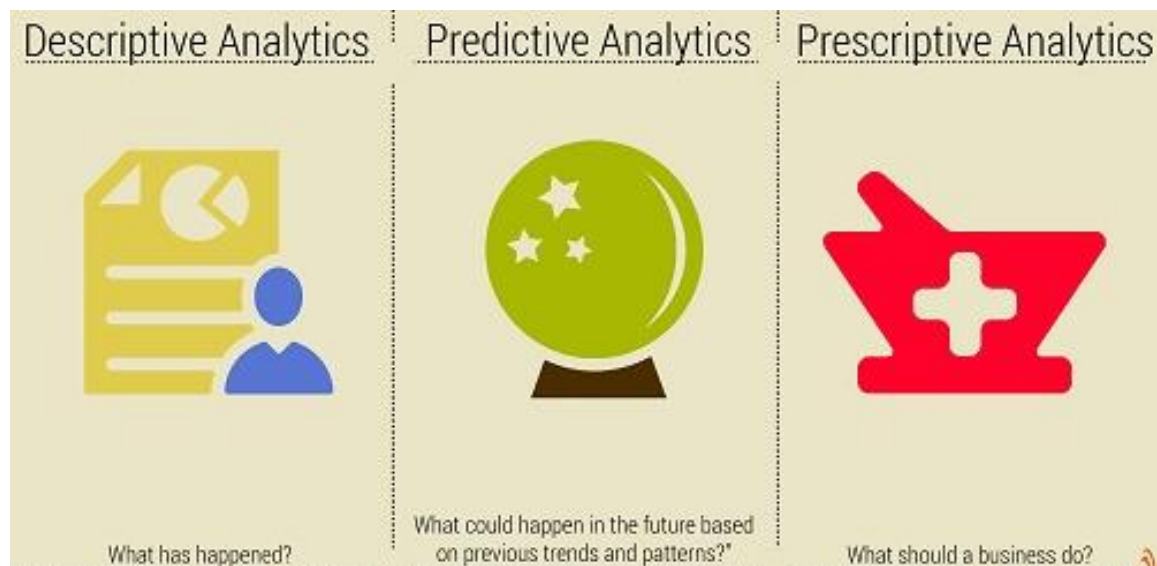


Figura 2: Descriptive Analytics, Predictive Analytics, Prescriptive Analytics (Fonte: Types of Analytics: descriptive, predictive, prescriptive analytics (2019) Project Pro).

- *Automated Analytics*: sono strumenti capaci di implementare autonomamente l'azione proposta secondo il risultato delle analisi svolte. A fronte dei risultati delle analisi descrittive e predittive, le Automated Analytics sono nella condizione di attivare delle azioni definite in conformità a delle regole, le quali possono essere a loro volta il frutto di un processo di analisi.

Le parole più rappresentative di quest'area sono "*artificial intelligence*" e "*machine learning*" cioè intelligenza artificiale (ovvero la disciplina che studia i fondamenti teorici, le metodologie e le tecniche che consentono la progettazione di sistemi hardware) e sistemi di programmi software e apprendimento automatico (ossia insegnare ai computer e ai robot a fare azioni ed attività in modo naturale, come gli esseri umani, usando metodi matematico-computazionali senza modelli matematici ed equazioni predeterminate).

<b>Categoria</b>	<b>Numero articoli</b>	<b>Autore</b>	<b>Anno</b>
<b>Accounting</b>	<b>5</b>	Huerta, Jensen	2017
		Amani, Fadlalla	2017
		Warren, Moffitt, Byrnes	2015
		Rezaee, Wang	2019
		Moll, Yigitbasioglu	2019
<b>Auditing</b>	<b>13</b>	Brown-Liburd,	2015

		Issa, Lombardi,	
		Cao, Chychyla, Stewart	2015
		Salijeni, Samsonova- Taddei, Turley	2019
		Yoon, Hoogduin, Zhang	2015
		Gepp, Linnenluecke, O'Neill, Smith	2018
		Earley	2015
		Wang, Cuthbertson	2015
		Tang, Karim	2019
		Tiberius, Hirth	2019
		Alles, Gray	2016
		Dagilienė, Klovienė	2019
		La Torre, Botes, Dumay, Odendaal	2019
		Rose, Rose, Sanderson, Thibodeau	2017
<b>Models</b>	<b>18</b>	Appelbaum, Kogan, Vasarhelyi,	2018
		Byrnes	2019
		Kraus, Valverde	2014
		Dilla, Raschke,	2015
		Dai, Li	2016
		Bao, Ke, Li, Yu, Zhang	2020
		Rahrovi Dastjerdi,	2019



	Foroghi, Kiani	
	Khrestina, Dorofeev, Kachurina, Usubaliev, Dobrotvorskiy	2017
	Mosteanu, Faccia	2020
	Sun, Vasarhelyi	2018
	Singh, Best	2016
	Dong, Liao, Zhang	2018
	Fay, Negangard	2017
	No, Lee, Huang, Li	2019
	Enget, Saucedo, Wright	2017
	Han	2017
	Guan, Levitan, Goyal	2018
	Bradford, Henderson, Baxter, Navarro	2020

Tabella 6. Suddivisione in categorie. (Fonte: personale)

Per ciascun'area individuata, sarà identificata una domanda di ricerca alla quale si andrà a rispondere.

## 2.2 Domande di ricerca

In questo paragrafo vengono introdotte le domande di ricerca riferite alle diverse aree, individuate nel paragrafo precedente sulla base degli argomenti trattati negli articoli selezionati.

Determiniamo le domande di ricerca riferite all'area *Big Data* e frode in ambito contabile. È importante soffermarsi sul **ruolo del contabile e analizzare se con l'introduzione dei *Big Data*, la sua figura abbia subito dei cambiamenti, in generale e in ambito della rilevazione della frode**, in particolare nel campo della contabilità forense poiché si occupa d'irregolarità finanziarie, attività fraudolente e

negligenza commerciali. È necessario soffermarsi su questo aspetto in quanto, si tratta di una nuova opportunità nuova per la figura del contabile, che permette di non subire cambiamenti radicali, consentendo di aggiungere un ruolo nuovo alla figura del commercialista o esperto contabile.

**Domanda 1a. Quali cambiamenti sono intervenuti nella figura del contabile, in generale e in ambito della rilevazione della frode, con l'introduzione dei *Big Data*?**

Inoltre è importante soffermarsi sulle **problematiche che il professionista incontra nell'utilizzo dei *Big Data***, perché sono un ostacolo per l'attività che il professionista deve svolgere.

**Domanda 1b. Quali problematiche incontra il professionista contabile nell'utilizzo dei *Big Data* per il rilevamento della frode?**

Si è arrivati a queste domande in quanto molti articoli toccano il tema della figura del contabile che utilizza i *Big Data*, elemento importante per questo tipo di attività, ma allo stesso tempo riscontra problemi nel loro utilizzo.

Nella seconda area cioè *Big Data* utilizzati per l'attività di *auditing*, è necessario soffermarsi sulle motivazioni del poco utilizzo dei *Big Data* in questo campo ma allo stesso tempo nel momento in cui vengono utilizzati è necessario analizzare i benefici derivati dal loro uso e il miglioramento che apportano nella rilevazione della frode. Ci domandiamo quindi, per quale motivo i *Big Data* sono così poco utilizzati in *audit*?

**Domanda 2. Se i *Big Data* fossero ampiamente utilizzati nel procedimento di rilevazione delle frodi contabili, quali benefici e miglioramenti potrebbero apportare a tale attività?**

Questa domanda è nata dal fatto che il ruolo del revisore nella rilevazione di eventuali frodi è importante e grazie all'utilizzo dei *Big Data* quest'attività potrebbe diventare più semplice. Infatti, il compito del revisore è individuare se l'errore è dovuto da un evento non intenzionale oppure chi lo commette lo pone in essere dolosamente (frode), al fine di ottenere un vantaggio ingiusto o illecito.

Infine l'ultima area si occupa di analizzare documenti che trattano modelli di *Big Data* nuovi o in precedenza applicati. La domanda che sorge in quest'area è:

**Domanda 3. I modelli già introdotti e analizzati in letterature risultano efficaci ed**

**efficienti in ambito di prevenzione della frode? Oppure risulta preferibile l'introduzione di nuovi modelli di prevenzione?**

È importante verificare la misurazione e la valutazione delle prestazioni che questi modelli possono offrire agli utilizzatori, per questo ci si soffermerà ad analizzare i documenti con l'ottica di individuare il beneficio che essi apportano all'attività di rilevazione della frode.

Questa domanda di ricerca è nata dal fatto che molti contributi recenti hanno sviluppato modelli nuovi o già applicati ed è quindi importante verificare il beneficio che essi apportano all'attività svolta.

Nel capitolo successivo saranno sviluppate le risposte alle domande di ricerca individuate nel presente capitolo, iniziando l'esposizione con una breve introduzione dell'argomento a livello generale e in seguito approfondendo il rapporto tra l'area selezionata e il tema "*Big Data and accounting fraud*".



## Capitolo 3 Risultato e analisi di ricerca

### 3.1. *Accounting*: Il ruolo del contabile nella prevenzione della frode con i *Big Data*

#### 3.1.1. Il rapporto esistente tra l'*Accounting* e i *Big Data*

*Big Data* e Contabilità è un argomento molto innovativo e attuale in quanto la correlazione tra i due fenomeni si è sviluppata e si sta consolidando negli ultimi anni.

Il mercato dei *Big Data* è cresciuto notevolmente da \$ 16,1 miliardi nel 2014 (Forbes, 2013a) a oltre \$ 50 miliardi nel 2016 (Kelly et al., 2015) e si ipotizza che continuerà a crescere con una previsione di circa \$ 67 miliardi entro il 2021 (Rezaee, Wang 2019).

Amani e Fadlalla (2017) sottolineano che nell'era delle economie globalizzate in rapida evoluzione e dei mercati altamente concorrenziali, le organizzazioni, per diventare competitivi, devono considerare e, più volte adottare o attuare, un'ampia varietà di filosofie, approcci e tecnologie di gestione innovativa (Dorsch, Yasin, 1998); in particolare, l'intelligenza artificiale (AI) è importante per il futuro della professione contabile (Eliott, 1992) e i sistemi intelligenti hanno introdotto molti miglioramenti del potere analitico multidimensionale e dell'efficienza dei processi contabili (Granlund, 2011).

La crescente importanza dei *Big Data* avrà un impatto significativo sulla contabilità. Ciò si rifletterà sul modo in cui i dati vengono accumulati e registrati, su come la gestione utilizza i dati per raggiungere gli obiettivi organizzativi e su come gli elementi di reporting vengono elaborati e assemblati (Warren, Moffitt, Byrnes, 2015).

I *Big Data* hanno trasformato la *business intelligence*<sup>3</sup> in quanto, in passato ci si concentrava sull'estrazione di informazioni dai dati aziendali archiviati in *data warehouse*<sup>4</sup> e *data mart*<sup>5</sup> per fornire analisi descrittive delle performance passate (Schmarzo 2013). Al contrario, i *Big Data* includono non solo dati interni, ma anche dati

---

<sup>3</sup> Ci si può solitamente riferire a:

1. un insieme di processi aziendali per raccogliere dati ed analizzare informazioni strategiche;
2. la tecnologia utilizzata per realizzare questi processi;
3. le informazioni ottenute come risultato di questi processi.

<sup>4</sup> collezione o aggregazione di dati strutturati, provenienti da fonti interne operazionali (DBMS) ed esterne al sistema informativo aziendale.

<sup>5</sup> raccoglitore di dati, specializzato in un particolare soggetto, che contiene un'immagine dei dati stessi, permettendo di formulare strategie sulla base dell'analisi degli andamenti passati.

esterni che potrebbe aiutare a fornire le informazioni previsionali necessarie per analisi predittive e prescrittive (Ransbotham, Kiron e Prentice, 2015). Per questo l'esperienza che hanno i contabili li rende adatti a guidare e collaborare alla realizzazione di progetti di *Big Data* (Huerta, Jensen, 2017).

La seconda conferenza annuale del *Journal of Information Systems* ha riunito ricercatori e specialisti del settore per discutere dell'impatto dei *Big Data* e dell'analisi dei dati sulla professione contabile (Huerta, Jensen, 2017). In particolare i relatori hanno discusso di come i contabili sono abituati a gestire i dati numerici e di come i *Big Data* hanno aggiunto testo, immagini, video e altri tipi di dati gratuiti che possono essere analizzati.

La gestione e l'analisi di questi tipi di dati richiedono nuove capacità analitiche e conoscenze tecniche. I partecipanti alla conferenza hanno sottolineato che le informazioni approfondite che si possono ottenere dai *Big Data* dipendono dalla loro capacità di gestire una grande varietà di dati, selezionare gli strumenti analitici appropriati e interpretare i risultati dell'analisi ma la sfida con i *Big Data* è identificare le domande giuste da porre.

Warren, Moffitt, Byrnes, (2015) sottolineano che i *Big Data* possono essere visti come una risorsa aziendale analoga all'immagine del marchio (Brown, Chui, Manyika 2011) e che stanno rapidamente diventando elementi chiave per stabilire e mantenere un vantaggio competitivo (Bughin, Livingston, Marwaha 2011). Nell'ultimo di una serie di sondaggi effettuati da *New Vintage Partners*, per valutare il passaggio ai *Big Data*, il 97,2% delle aziende intervistate sta intraprendendo un percorso verso l'adozione ai *Big Data*, anche se per la maggior parte di esse l'investimento rimane relativamente modesto. Gli intervistati sostengono di ottenere benefici in quanto acquisiscono risultati misurabili, favoriscono il miglioramento del processo decisionale, del servizio offerto ai clienti e riducono i costi (Moll, Yigitbasioglu, 2019). Il *Chartered Global Management Accountants* (CGMA) invece ha riferito che il 50% dei leader aziendali classifica i *Big Data* e il *data mining* tra le prime dieci priorità aziendali fondamentali per l'era del business basata sui dati (CGMA, 2013) (Amani, Fadlalla, 2017).

Ciò nonostante è necessario considerare la minaccia dell'automazione alla professione contabile. Huerta e Jensen (2017) specificano che i partecipanti alla conferenza hanno espresso opinioni divergenti sul fatto che i progressi dell'intelligenza artificiale, resi possibili dai *Big Data*, avrebbero portato all'automazione delle attività contabili. Sebbene tutti abbiano concordato sul fatto che alcuni compiti saranno senza dubbio di

routine automatizzati che richiedono un giudizio professionale minimo, non vi è stato consenso sul fatto che l'automazione eliminerebbe alcuni dei compiti contabili più complessi; ad esempio compiti che richiedono una profonda conoscenza delle imprese o un giudizio professionale, difficilmente possono essere implementati dagli attuali sistemi di intelligenza artificiale.

Moll e Yigitbasiolu (2019) affermano la teoria sopracitata da Huerta e Jensens (2017) cioè la non automatizzazione di alcune attività contabili e quindi difficilmente sostituibili dai *Big Data* ma allo stesso tempo definiscono questa introduzione come: “*These changes (AI, machine learning, robotic process automation, etc.) are redefining and expanding the role of accountants and making our cultivation of skills such as data analytics, data visualization, storytelling and strategic management more important than ever before...*” cioè il ruolo del contabile si sta ridefinendo e ampliando, rendendo le loro competenze sempre più importanti.

### **3.1.2. Utilizzo dei *Big Data* per la rilevazione di frode in ambito contabile**

I *Big Data* possono essere utilizzati per analizzare tutte le transazioni e identificare modelli di potenziali frodi che potrebbero non essere rilevabili utilizzando altri strumenti (Huerta, Jensen, 2017).

Un presupposto della tecnologia *blockchain* è che le transazioni saranno trasparenti e conterranno meno errori, rendendo più difficile nascondere le frodi. Tuttavia, mentre una maggiore trasparenza potrebbe suggerire una minore probabilità di frode, l'anonimato fornito da alcune criptovalute potrebbe avere l'effetto opposto (Moll, Yigitbasioglu, 2019).

A tal proposito si possono verificare due situazioni:

- la cecità disattenta;
- la distorsione della conferma.

La cecità disattenta (propensione a ignorare le informazioni che non sono al centro della nostra attenzione) influisce sulle decisioni supportate dai *Big Data* perché i contabili potrebbero concentrarsi esclusivamente sui risultati dei *Big Data* e non osservare altri modelli di business che non sono acquisiti nel sistema; infatti, potrebbero concentrarsi sui risultati di un'analisi del modello di frode che non mostri segni di frode. Tuttavia, concentrandosi principalmente su tali risultati, potrebbero essere “ciechi” rispetto ad altri segnali di potenziali frodi che il sistema non rileva.

La distorsione della conferma (propensione a ignorare le informazioni che non supportano le idee prefissate) ha un impatto sulle decisioni supportate dai *Big Data* perché i risultati a supporto delle idee prefissate potrebbero essere accettate come guida in quanto fondate su basi ben definite, mentre i risultati che non supportano le idee prefissate potrebbero essere ignorate (Huerta, Jensen, 2017).

Possono poi verificarsi due tipi di pregiudizi:

- cognitivo;
- di sistema.

Tuttavia, i *Big Data* non possono eliminare i pregiudizi del decisore (pregiudizi cognitivi) e, come in altri sistemi software, i pregiudizi possono essere incorporati inavvertitamente nel sistema (pregiudizi del sistema). I pregiudizi cognitivi sorgono a causa delle limitazioni umane nell'elaborazione delle informazioni e ciò porta a decisioni non ottimali. Queste limitazioni sono inerenti alla natura umana e non sono collegate ad alcun tipo di sistema o aiuto decisionale. I pregiudizi del sistema, d'altra parte, sono errori programmati a seguito delle decisioni prese dai progettisti quando il sistema viene costruito.

A tal proposito le aziende sentono sempre più l'esigenza di rilevare questi pregiudizi di sistema e cognitivi e per questo la richiesta di servizi di contabilità forense è in aumento in quanto le imprese e gli investitori continuano a sollevare preoccupazioni su frodi, irregolarità e casi di corruzione. Ad esempio, le organizzazioni imprenditoriali perdono ogni anno circa il 5% delle loro entrate per frode, che possono superare 3,5 miliardi di dollari in tutto il Mondo (ACFE, 2016).

La contabilità forense è emersa come una delle principali aree delle pratiche contabili, che comprende l'esame delle frodi, l'anticorruzione e la corruzione, la valutazione aziendale, il supporto per controversie legali, la testimonianza di esperti e la sicurezza informatica (Crumbley et al., 2015; Rezaee et al., 2004).

Per aiutare ad aggiornare e far avanzare i curricula di contabilità forense con contenuto di *Big Data*, è stata condotta una ricerca, basata su un sondaggio tra accademici e professionisti in Cina, per raccogliere informazioni sulla necessità della contabilità forense di integrare le attività con i *Big Data*.

In particolare la maggior parte degli intervistati, sia accademici che professionisti, hanno dato il loro parere sullo sviluppo dei *Big Data* in contabilità forense.



	(%)			
	<i>Big data</i>		<i>Forensic Accounting</i>	
	<i>Chinese academics</i>	<i>Chinese practitioners</i>	<i>Chinese academics</i>	<i>Chinese practitioners</i>
Increase?	94	83	66	66
Remain the same?	2	8	20	21
Decrease?	0	4	3	9
Unsure?	4	5	11	4
Total	<i>100%</i>	<i>100%</i>	<i>100%</i>	<i>100%</i>

Figura 3. Percentuale di interesse degli intervistati in merito ai *Big Data* in contabilità forense. (Fonte: Relevance of *Big Data* to forensic accounting practice and education - Rezaee, Wang, 2019)

Si riscontrano delle differenze nelle risposte, il 94% degli accademici, rispetto all'83% dei professionisti hanno riferito che la domanda e l'interesse per i *Big Data* continueranno ad aumentare ed entrambi i gruppi di intervistati si aspettano che la domanda e l'interesse per i *Big Data* aumenterà più della domanda di contabilità forense. Una spiegazione è la recente comparsa dei *Big Data* rispetto alla maturità accettata da accademici e professionisti, della contabilità forense. Tuttavia c'è più ottimismo da parte dei professionisti rispetto agli accademici sullo sviluppo dei *Big Data*. La grande positività delle risposte all'utilizzo dei *Big Data* in contabilità forense in Cina e Hong Kong, è da ricondurre a tre motivi. Innanzitutto, la contabilità forense a Hong Kong e in Cina è cresciuta significativamente negli ultimi anni (Rezaee et al., 2016). In secondo luogo, sono presenti prove che suggeriscono che i paesi del Pacifico asiatico (APAC) sono la regione in più rapida crescita per il mercato dei *Big Data* (Markets, Markets, 2017). In terzo luogo, la Cina è avanzata come la seconda più grande economia del mondo vulnerabile agli scandali e alle frodi nelle aziende (Hung et al., 2015).

Il sondaggio riporta che entrambi i gruppi di intervistati (accademici e professionisti) ritengono che l'uso dei *Big Data* migliori le pratiche di contabilità forense, ma allo stesso tempo le minacce alla sicurezza dei dati limitano il loro uso. Ciò è coerente con EY (2016) secondo cui l'uso dei *Big Data* è aumentato notevolmente, ma la sicurezza informatica rimane un problema importante. Ciò nonostante il sondaggio rileva che le tecniche di *Big Data* tra cui analisi descrittive e prescrittive, l'acquisizione di dati e attributi di *Big Data* come accuratezza, affidabilità, accessibilità e coerenza sono importanti per le pratiche di contabilità forense (Rezaee, Wang, 2019).

Attualmente i contabili forensi sono in grado di ottenere una grande quantità di dati sia strutturati (ad es. contabilità generale o dati di transazione) che non strutturati (ad es. campi di posta elettronica, voce o testo libero in un database), insieme a una quantità

crescente di fonti di dati non tradizionali come elenchi di controllo di terze parti, mezzi di informazione, descrizioni di pagamenti, comunicazioni e-mail e *social media*. Di conseguenza, i contabili forensi usano strumenti tecnologici avanzati nelle loro pratiche investigative, ad esempio, i *social media* e il monitoraggio del Web, la ricerca e l'analisi vocale, gli strumenti di visualizzazione e reportistica (EY, 2016).

A causa della presenza di grandi quantità di dati, i contabili forensi utilizzano sempre più i *Big Data* nelle loro pratiche per gestire set di dati che con un foglio di calcolo tradizionale sarebbero difficili da gestire (EY, 2016); usano anche la visualizzazione dei dati, l'analisi predittiva, l'analisi del comportamento, l'analisi dei contenuti, l'analisi dei social network, l'analisi geo spaziale e numerose tecniche antifrode avanzate per superare le carenze delle tradizionali tecniche di *database* basate su regole, come la progettazione di query.

I seguenti punti illustrano l'uso dei *Big Data* nella pratica della contabilità forense. In primo luogo, quando i contabili forensi indagano su casi di frode, prendono in considerazione le norme o i regolamenti specifici del settore e usano le parole chiave per identificare potenziali frodi. In secondo luogo, utilizzando attività storiche o dati di transazione, possono utilizzare modelli predittivi e altre analisi avanzate per rilevare transazioni sospette e anomale, eventi ad alto rischio o potenziali comportamenti o attività fraudolente. In terzo luogo, eseguendo il *mining*, ovvero l'estrazione di dati, su più *database* (come database di clienti o di terze parti), possono utilizzare algoritmi delle entità per identificare relazioni nascoste e indagare su conflitti d'interesse o d'identità. In quarto luogo, utilizzano l'analisi dei *social network* per rilevare relazioni nascoste, venditori fasulli o conti bancari falsi quando analizzano dati strutturati e non strutturati nel formato di elementi visivi e collegamenti dai *social media*. In quinto luogo, sono disponibili una grande quantità di dati di testo non strutturati, libero di voci di giornale, descrizione del pagamento, dettagli delle spese, e-mail, social media, documenti, presentazioni e dischi rigidi di singoli dipendenti o organizzazioni. I contabili forensi usano l'estrazione del testo o l'analisi del testo con regole e tecniche statistiche per scoprire i sentimenti e i significati concettuali di grandi quantità di dati di testo, che aiutano a identificare potenziali frodi o non conformità nell'organizzazione. Infine, oltre ai tradizionali semplici fogli di calcolo o diagrammi e grafici, i contabili forensi utilizzano tecniche di visualizzazione dei dati e *dashboard* (pannello di controllo) interattivi per presentare le prove in modo facile da capire.

Nel settore della contabilità forense, Wang (2010) ha fornito una revisione sulla rilevazione delle frodi contabili basata sul *data mining* (modalità di estrazione dei dati) e ha sintetizzato le strutture dei dati, gli algoritmi, i risultati e la valutazione delle prestazioni del modello, con l'obiettivo di aiutare i commercialisti nella selezione dei dati adeguati e tecnologie di *data mining* apposite per il rilevamento di frodi. Inoltre, Ngai et al. (2011) hanno esplorato l'applicazione di tecniche di *data mining* nel rilevamento di frodi finanziarie e Gray e Debreceeny (2014) hanno fornito una tassonomia per guidare la ricerca sull'applicazione del *data mining* al rilevamento di frodi negli audit di bilancio. Ad esempio, utilizzando il *data mining* predittivo, un sistema bancario potrebbe avvisare un cliente con carta di credito di un addebito potenzialmente fraudolento (Amani, Fadlalla, 2017).

La revisione della letteratura di Amani e Fadlalla (2017) ha mostrato l'uso prevalente del *data mining* da parte di ricercatori e professionisti per rilevare le frodi, affrontando diversi livelli e aree di frode. Alcuni si sono concentrati sulla rilevazione del rischio di frode a livello più macro del livello di incarico di revisione (Comunale et al., 2010), altri si sono concentrati sulla rilevazione di frodi a livello più micro di transazioni commerciali (Debreceeny e Gray, 2010; Bella et al., 2009; Tackett, 2013). Inoltre Debreceeny e Gray (2010) hanno studiato la frode del giornale di registrazione usando l'analisi delle cifre e hanno scoperto che la distribuzione delle prime cifre degli importi in dollari del giornale differiva da quella prevista dalla legge di *Benford*<sup>6</sup>, Bella et al. (2009) hanno sviluppato un'architettura auto-organizzante a quattro fasi per il rilevamento delle frodi della fatturazione elettronica e Tackett (2013) ha suggerito l'uso di regole per rilevare le frodi attraverso la ricerca di schemi e relazioni durante l'esame dei sistemi digitali di un'azienda. D'altra parte, Bay et al. (2006) si sono concentrati sull'identificazione delle irregolarità a livello di contabilità generale e Jans et al. (2010), Jans et al. (2011) e Owusu-Ansah et al. (2002) si sono soffermati sull'individuazione di frodi a livello di ciclo economico o di processo. Mentre Jans et al. (2010) hanno utilizzato tecniche di *data mining* descrittive per rilevare e ridurre il rischio di frode interna a livello del ciclo di approvvigionamento, Jans et al. (2011) hanno esaminato l'efficacia delle procedure di audit per l'individuazione delle frodi a livello di ciclo delle scorte e di

---

<sup>6</sup> La distribuzione di Benford, meglio nota come legge di Benford, o come legge della prima cifra, descrive la distribuzione di probabilità con cui compare la prima cifra dei numeri in molti esempi di raccolte di dati reali.

deposito e Owusu-Ansah et al. (2002) hanno impiegato il *mining* di processi aziendali per mitigare la frode delle transazioni interne nei processi di approvvigionamento (Amani, Fadlalla, 2017); allo stesso modo, Yu et al. (2013) hanno costruito modelli basati su tecniche di *data mining* per rilevare e classificare le violazioni alla divulgazione delle informazioni contabili da parte delle società quotate e Kochetov Akozloski et al. (2011) hanno utilizzato il *data mining* per migliorare i giudizi su eventi di gestione fraudolenta. I *Big Data* hanno anche ricevuto un'accettazione comune e un'applicazione pratica nella comunità aziendale. Ad esempio, oltre il 98% di tutte le informazioni archiviate è ora elettronico (Rezaee, Wang 2019), rispetto a circa il 25% delle informazioni digitali nel 2000 (Cukier, Mayer-Schonberger, 2013; Crumbley et al., 2015). Anche Ernst and Young (EY), con un sondaggio, ha sostenuto questa tesi, dimostrando che “79 per cent of respondents use more than 10 million records, which are typically outside the domain of spreadsheets and require more sophisticated tools for analysis” cioè il 79% degli intervistati utilizza più di 10 milioni di registrazioni, spesso al di fuori del classico foglio di calcolo, richiedendo strumenti più sofisticati (Rezaee, Wang 2019).

La ricerca di indicatori di frode nel campo dell'informativa finanziaria non si limita all'uso della parte numerica del bilancio, che era al centro di molte ricerche precedenti, ma si estende alla parte qualitativa. Allo stesso tempo anche nella relazione annuale è possibile esaminare il contenuto testuale per prevedere la frode (Goel et al. 2010, Goel, Gangolly 2012) e nella parte qualitativa dei rendiconti finanziari (Gupta, Gill, 2012a)(Amani, Fadlalla, 2017).

Negli Stati Uniti è possibile utilizzare i dati e-mail per limitare le perdite di frode. Queste perdite hanno raggiunto circa \$ 652 miliardi nel solo 2009 e i dipendenti insoddisfatti sono stati i principali contribuenti (Holton 2009). Le perdite di frode statunitensi continuano a salire, e nel 2012 sono state stimate a \$ 1 trilioni di dollari (ACFE 2013). Nel cercare misure per ridurre le frodi attribuibili ai dipendenti, l'estrazione del testo dei messaggi e-mail, identifica i lavoratori scontenti e prevede e affronta il rischio di frode (Holton 2009). Questo metodo è molto importante in quanto scopre informazioni pertinenti non rivelate in un tradizionale *audit* di frode. È possibile utilizzare il metodo del *Fraud Triangle Analytics* (sistema di scoperta delle frodi) il quale applica i principi del triangolo delle frodi nell'analisi dei messaggi e-mail per rilevare i dipendenti con l'opportunità, la motivazione e la razionalizzazione di commettere frodi (Torpey, Walden, Sherrod 2009). Nonostante ciò l'email è diventata la forma di comunicazione

predominante con soggetti esterni e ciò può comportare la possibilità di manomissione del documento se utilizzato per le conferme esterne (La Torre, Botes, Dumay, Odendaal, 2019).

In conseguenza all'introduzione e utilizzo di questi sistemi, si sviluppano le violazioni informatiche (trasferimento illecito di fondi, interruzioni di operazioni critiche o furto di proprietà intellettuale/dati personali riservati) e minacce interne (insider malintenzionati, che rubano, manipolano o distruggono dati, frodi e sabotaggi non autorizzati della tecnologia dell'informazione commerciale) che stanno emergendo come la frode in più rapida crescita.

È quindi importante valutare i requisiti e i rischi relativi alla privacy e alla sicurezza; i relatori del *Journal of Information Systems* (Huerta, Jensen, 2017) hanno discusso di come il volume, la varietà e le informazioni dettagliate archiviate nei repository (magazzino) di *Big Data* aumentano i rischi associati alla violazione dei dati e le conseguenze legali e commerciali. I membri della conferenza hanno anche elaborato le sfide che i contabili devono affrontare nel decidere sull'uso appropriato dei *Big Data*, incluso il rispetto di molteplici leggi e la valutazione di potenziali conseguenze indesiderate. I ragionieri implementano controlli per garantire che solo gli utenti autorizzati abbiano accesso alle informazioni presso la propria azienda o quella dei propri clienti. I membri del panel hanno indicato che con il passaggio dall'archiviazione su supporto cartaceo a quella digitale, la protezione delle informazioni è passata dall'implementazione dei controlli fisici alla sicurezza informatica.

I relatori (Huerta, Jensen, 2017) hanno sostenuto che i *Big Data* hanno trasformato il tipo di informazioni che vengono acquisite sui clienti e, in tal modo, hanno aumentato i rischi associati alla violazione dei dati. I *Big Data* possono archiviare e analizzare tutte le informazioni finanziarie e non finanziarie acquisite su un cliente, ma il fatto che sia possibile acquisire queste informazioni non significa che sia necessario riceverle. I ricercatori hanno anche sostenuto che le aziende che utilizzano un approccio di acquisizione di tutti i dati potrebbero aumentare inutilmente i loro rischi in un momento in cui la *Federal Trade Commission* (FTC) prenderà una posizione ferma sulla violazione dei dati (Pentland 2014). Una violazione dei dati, come ad esempio una frode, con conseguente perdita catastrofica potrebbe portare a una reazione eccessiva normativa che creerebbe una limitazione all'uso dei dati (Pentland 2014).

Un partecipante alla conferenza ha anche affermato che, oltre al volume, i sistemi *Big Data* memorizzano dati molto dettagliati, anziché un insieme di singole informazioni aggregate tra di loro. Per questo motivo, il danno potenziale derivante dalla violazione di informazioni dettagliate è maggiore rispetto a quello associato alle informazioni aggregate. Si sottolinea però che le misure di sicurezza dipendono non solo dalla quantità di dati, ma anche da dove essi sono custoditi (Huerta, Jensen, 2017).

I tipi di misure di sicurezza richieste per i sistemi *Big Data* sono simili a quelli di altri sistemi, tuttavia, la quantità e la natura disaggregata dei dati memorizzati hanno aumentato i rischi. Di conseguenza, anche l'intensità e il ruolo delle misure di sicurezza nei sistemi *Big Data* sono aumentati.

I contabili dovrebbero preoccuparsi anche dei potenziali rischi dovuti all'uso inappropriato dei dati. Come notato durante la conferenza, la percezione che un'azienda abbia superato il limite nell'uso dei dati dei clienti può eliminare la fiducia dei consumatori nell'azienda per questo, numerosi ricercatori e organizzazioni hanno sostenuto una maggiore trasparenza nell'uso dei *Big Data* per creare fiducia nei consumatori. Per rafforzare la fiducia, Pentland (2014) propone "*New Deal on Data*" in cui le aziende forniscono una maggiore trasparenza nella raccolta e nell'utilizzo dei dati dei clienti e offrono ai consumatori il diritto di controllare i propri dati, in modo simile al controllo che hanno all'interno delle proprie aziende. Si teme però che una maggiore trasparenza possa indurre molti consumatori a rinunciare a consentire alle aziende di raccogliere e condividere i propri dati (Pentland, 2014).

Negli Stati Uniti i contabili dovrebbero essere consapevoli non solo delle normative sulla privacy e sulla trasparenza, ma anche di altre normative applicabili alle società controllate. Sebbene vi siano state richieste di maggiore trasparenza nell'uso dei dati da parte dei regolatori negli Stati Uniti (FTC<sup>7</sup> 2014), come discusso durante la conferenza, in Europa, il diritto alla privacy è considerato un diritto umano fondamentale.

Una questione chiave emersa durante la discussione è stata che le aziende dovrebbero valutare le implicazioni delle norme Europee emanate dal Regolamento generale sulla protezione dei dati (GDPR), entrata in vigore a maggio 2018<sup>8</sup>. Ai sensi del GDPR, le

---

<sup>7</sup> Federal Trade Commission

<sup>8</sup> Dal 25 maggio 2018 è divenuto pienamente applicabile in tutti gli Stati membri il Regolamento Ue 2016/679, noto come GDPR (General Data Protection Regulation) – relativo alla protezione delle persone fisiche con riguardo al trattamento e alla libera circolazione dei dati personali.

società devono fornire alle persone: (1) un maggiore accesso ai loro dati, (2) la possibilità di richiedere la cancellazione dei loro dati, (3) notifiche tempestive di violazioni dei dati e (4) la capacità di revocare il consenso al trattamento dei loro dati (IBM Analytics IBM 2016). Il mancato rispetto del GDPR può comportare multe salate fino al 4 per cento delle entrate globali.

Altro problema molto importante è la diminuzione del personale dipendente necessario nel momento in cui viene introdotto un sistema di *Big Data* ma anche la presenza di professionisti non qualificati nell'utilizzo di questi strumenti nella loro attività. Questo perché non viene effettuata una formazione curriculare adeguata che mette in correlazione i due fenomeni. L'istituto CPA di Hong Kong e l'istituto CPA cinese chiedono alle università di aggiornare i propri curricula contabili per preparare al meglio gli studenti di contabilità alle sfide fornite dai *Big Data*. Lo studio eseguito da questi due istituti è una risposta alla richiesta di una maggiore copertura dell'educazione alla contabilità forense digitale, ritenuto fondamentale per lo svolgimento al meglio della loro professione (Rezaee, Wang, 2019).

### **3.1.3 Osservazioni finali *Big Data* e frode in ambito contabile**

In conclusione possiamo sostenere che i contabili possono affidare le loro decisioni all'utilizzo dei *Big Data* per il rilevamento della frode ma dovrebbero tenere in considerazione, sulla base dei dati, anche la loro esperienza e il giudizio professionale; questo perché l'eccessiva dipendenza dai *Big Data* può essere dannosa poiché vengono accettate le informazioni senza che vengano messe in discussione, perdendo il sano scetticismo professionale necessario per valutare le informazioni; allo stesso modo se venissero ignorati i risultati si sprecherebbero le risorse investite per questo tipo di attività.

S'inizia a percepire la figura del contabile come quel ruolo che non si occupa solo della chiusura dei bilanci, emissione di F24 per il pagamento delle imposte ma anche quella figura che accompagna l'azienda in un percorso di crescita e di maggiore efficienza.

Allo stesso tempo viene considerata come la prima figura che potrebbe rilevare la frode in una registrazione contabile, in fase di chiusura di bilancio o in fase di contabilità

---

Il suo obiettivo è quello di armonizzare e semplificare le norme riguardanti il trasferimento di dati personali dall'Ue verso altre parti del mondo.

forense, in un modo più digitale grazie all'utilizzo dei *Big Data*, abbandonando il foglio di calcolo tradizionale, troppo semplice per lo svolgimento di determinate attività.

È importante però considerare che l'introduzione dei *Big Data* provoca anche un problema di privacy e di trasparenza che spesso viene tralasciato ma che è molto importante in quanto memorizzano dati molto dettagliati, anziché un insieme di singole informazioni aggregate tra di loro, che spesso vengono utilizzate per altre motivazioni (per esempio per questioni personali).

### **3.2 Auditing: l'utilizzo dei *Big Data* per la rilevazione di frodi in ambito di revisione**

#### **3.2.1 Utilizzo dei *Big Data* in ambito di revisione**

Molte organizzazioni hanno utilizzato i *Big Data* per prendere decisioni più appropriate e più tempestive sulla propria attività, come per la valutazione del rischio (King, 2013, Myers 2013) ma ciò ha creato difficoltà per i revisori nell'analizzare le transazioni, in quanto c'è stato un aumento significativo del volume e della complessità delle transazioni contabili; questo ha portato al potenziale cambiamento del modo in cui i revisori prendono decisioni (vale a dire la valutazione del rischio) e raccolgono prove di audit.

Tuttavia, nonostante la disponibilità di strumenti avanzati di analisi dei dati, questi strumenti sono raramente utilizzati negli audit di bilancio (Alles 2014; Gray, Debreceeny 2013) e vi è consenso limitato sul ruolo che i *Big Data* avranno nell'auditing (Alles 2013) (Brown-Liburd, Issa, Lombardi, 2015). Anche le letterature di Gepp, Linnenluecke, O'Neill, Smith, (2018) e Earley (2015), rilevano la poca diffusione dell'utilizzo dei *Big Data* nell'auditing rispetto ad altri campi più sviluppati. In altre letterature si sostiene che la causa sia la limitazione alla conoscenza delle conseguenze dell'utilizzo dei *Big Data* negli incarichi di revisione (Wang, Cuthbertson, 2015), la limitata ricerca sulla comprensione delle motivazioni dell'uso dei *Big Data* poiché gli studi attuali non tentano di spiegare perché le società di revisione debbano effettivamente utilizzarli (Dagilienè, Klovienè, 2019) anche se sono considerati una parte sempre più essenziale della loro pratica di affidabilità (Alles, Gray, 2016).

La sfida principale per la professione di revisore è come trarre valore dai *Big Data* e garantire che i giudizi e le decisioni dei revisori si basino su informazioni di qualità pertinenti ed affidabili.



La problematica maggiore risulta essere l'analisi e l'interpretazione dei risultati poiché l'output produce quantità importanti di dati (Issa, Kogan, 2014). Nonostante i potenziali problemi legati al sovraccarico d'informazioni, è possibile utilizzare i *Big Data* per l'attività di revisione (Brown-Liburd, Issa, Lombardi, 2015). Salijeni, Samsonova-Taddei, Turley, (2019) sostengono che sia riconosciuto che l'accesso a dati di grandi dimensioni può aiutare i revisori, ad esempio ad aumentare il livello di fiducia (e a ridurre la materialità), può anche avere un impatto significativo sul modo in cui alcuni rischi sono classificati e gestiti nel corso di un incarico e sugli sforzi dei revisori per raccogliere elementi probativi sufficienti ed adeguati, che possono essere migliorati. Il sovraccarico di dati soprattutto di quelli strutturati e semi strutturati, può essere aiutato grazie all'utilizzo dei *Big Data*. Una problematica che si riscontra è che solo una grande società di revisione contabile può disporre di risorse e strumenti sostanziali sufficienti per poter controllare una società di grandi dimensioni e quindi con grandi quantità di dati; una piccola società di revisione incontrerebbe delle difficoltà nel tentativo di utilizzare i *Big Data* a causa della mancanza di personale qualificato e capacità tecnologiche (Dagilienè, Klovienè, 2019).

Queste informazioni eccessive possono sovraccaricare il processo decisionale, rendendolo meno efficiente e meno efficace, portando a decisioni improprie (Casey 1980; Malhotra 1982), complicazioni nel distinguere le informazioni rilevanti (Jacoby 1977), difficoltà nel riconoscere la correlazione tra dettagli e prospettiva generale (Schneider 1987), trascuratezza per grandi quantità di informazioni (Herbig, Kramer 1994; Sparrow 1999, Bawden 2001) e tempi di decisione più lunghi (Jacoby 1984) (Brown-Liburd, Issa, Lombardi, 2015).

Tutte le principali società di revisione *Big Four* hanno investito ingenti somme di denaro negli ultimi anni per acquisire o sviluppare strumenti di *Big Data* (Salijeni, Samsonova-Taddei, Turley, 2019). Ernest Young afferma: *"The audit of the future will bear little resemblance to the traditional audit CFOs are accustomed to receiving today. In fact, the way organizations conduct audits will change more in the next 5-10 years given the evolution of technology and analytics. Data analytics, new technology and access to detailed industry information will all combine to help auditors better understand the business, identify risks and issues and deliver additional insights. Moreover, the ability to review and analyze entire sets of data, rather than applying sampling techniques, will help bring more confidence to the audit."* Pone l'accento sul cambiamento che i CFO delle

aziende subiranno negli anni in campo della revisione, in particolare nei prossimi 5-10 anni, grazie all'evoluzione tecnologica; inoltre analisi dei dati, nuove tecnologie e accesso ad informazioni dettagliate del settore si uniranno per aiutare i revisori a comprendere meglio il business, identificare i rischi e i problemi e fornire ulteriori approfondimenti all'attività, rendendola ancora più affidabile.

Allo stesso tempo Deloitte afferma: *"At Deloitte we're investing several hundred million dollars in data analytics and artificial intelligence with some cutting-edge applications that we really believe differentiate us and our audit approach. When we use these tools, we're able to get greater coverage. We're able to more quickly identify risks. We're able to complete audit with a higher level of quality and ultimately deliver a greater level of insight to our clients."* L'investimento effettuato da queste *Big Four* è importante e credono molto nel valore aggiunto che questi strumenti sono in grado di dare all'attività di audit in termini di qualità. Anche PWC afferma che è inconcepibile che i revisori non utilizzino i *Big Data* nel momento in cui i loro clienti ne fanno affidamento (Alles, Gray, 2016).

I *Big Data*, in quanto strumento di IT, possono avere un impatto diretto sul processo di revisione influenzando la fase di revisione dell'incarico mentre un impatto indiretto sulla fase di pianificazione dell'audit, poiché la strategia di audit e i piani di audit sono sviluppati in base ai dati e alle informazioni provenienti dall'analisi dell'ambiente del cliente; può inoltre avere un'influenza diretta sulla conformità e sui test sostanziali nonché su valutazioni e relazioni (Dagilienè, L., Klovienè, 2019).

La Torre et al. (2018) hanno riscontrato che la "voracità" per i dati rappresenta un'ulteriore "V" dell'ecosistema dei *Big Data*, risultando in una continua ricerca dei dati oltre i confini legali ed etici. Crimini informatici, violazioni della sicurezza dei dati e violazioni della privacy caratterizzano i *Big Data* e minacciano il capitale intellettuale e la creazione di valore delle organizzazioni (La Torre, Botes, Dumay, Odendaal, 2019). In un recente sondaggio europeo condotto da Wakunuma e Stahl (2014), la mancanza di attenzione alla privacy dei dati ha subito un cambiamento a causa dell'espansione dell'utilizzo dei *Big Data*; sia i responsabili politici che i ricercatori delle tecnologie dell'informazione e della comunicazione hanno identificato le preoccupazioni sulla privacy come una delle principali questioni etiche all'interno delle nuove tecnologie emergenti (La Torre, Botes, Dumay, Odendaal, 2019).

Zhao et al. (2004) ritengono che “*the increasingly pervasive use of IT and its growing power not only threatens auditors in several ways but also offers opportunities*” cioè l’uso sempre più diffuso dell’IT e quindi dei *Big Data* minaccia i revisori in diversi modi ma offre anche opportunità.

### **3.2.2 Big Data e rilevazione della frode nel campo della revisione**

La parola audit deriva dal latino "audire", che significa ascoltare (Rasinski et al., 2011) e si riferisce al medioevo quando i revisori, per conto dei proprietari terrieri, ascoltavano e controllavano l'accuratezza dei conti.

Secondo Van Peurse et al. (2011) all'inizio i revisori erano responsabili della gestione delle attività e dei compiti che ruotavano attorno al rilevamento delle frodi e alla protezione dall'appropriazione indebita di fondi. Tuttavia, il più grande cambiamento nei compiti svolti dagli auditor è stato guidato dalla rivoluzione industriale quando i cambiamenti nelle strutture delle civiltà hanno causato esigenze di audit (Matthews, 2006, p. 7). Durante la fine del XVIII-inizio del XIX secolo, una maggiore necessità di finanziamenti e una necessità d’incorporazioni (il Joint Stock Companies Act 1844) e relazioni finanziarie hanno portato a cambiamenti significativi negli atteggiamenti, causando un impatto sui compiti svolti dai revisori, introducendo la necessità di verificare le relazioni finanziarie (Van Peurse et al., 2011). Nella metà del XIX secolo la proposta di revisione fu inclusa nel *Companies Act (UK)* del 1862<sup>9</sup>, portando all’aumento della domanda di servizi di revisione (Brown, 1962); quindi tra la metà del 1850 e il 1905 ci fu un aumento della richiesta di revisione delle transazioni e preparazione di conti e bilanci corretti (Brown, 1962, p. 698). Per la maggior parte delle aziende, il rilevamento di frodi è rimasto uno dei compiti principali del revisore, ma nel 1933 il rilevamento di frodi ed errori nelle società statunitensi diventò un compito secondario (Brown, 1962, p. 700). Pertanto, i compiti svolti dai revisori durante il periodo 1890-1930 variarono notevolmente, mostrando poca coerenza (Becker, 1980). Con il passare del tempo, l’insieme dei compiti dei revisori è andata al di là del rilevamento delle frodi e quelli stabiliti all’inizio del 1960 costituiscono ancora oggi la base della pratica di audit. Nonostante i revisori continuino gli sforzi per indirizzare ed educare il pubblico in merito alla loro ridotta responsabilità sul rilevamento di frodi che si verificano nelle

---

<sup>9</sup> Legge del Parlamento del Regno Unito che regolava il diritto societario del paese.

aziende (Koh, Woo, 1998), la percezione del pubblico persiste (La Torre, Botes, Dumay, Odendaal, 2019).

Dopo questa breve introduzione sulla storia della revisione, possiamo introdurre l'utilizzo dei *Big Data* in audit per il rilevamento delle frodi.

Ci sono alcune caratteristiche dell'analisi dei *Big Data* che stanno inducendo gli utenti a ripensare al modo in cui i dati vengono utilizzati. Innanzitutto, è sempre più possibile analizzare tutti o quasi tutti i dati piuttosto che solo un piccolo sottoinsieme o campione curato. Ciò può portare a modelli più robusti di prima. Ad esempio, se un revisore desidera determinare quali caratteristiche delle voci di giornale sono indicatori di rischio di errore o frode, è possibile analizzare tutte le voci di giornale per quanto siano state conservate registrazioni, e utilizzare queste informazioni per identificare le voci di giornale correnti che sono davvero insoliti.

Dall'analisi dei *Big Data* in ambito di revisione è probabile che l'attività di audit tragga vantaggio soprattutto:

- nell'individuare e valutare i rischi associati all'accettazione o al proseguimento di un incarico di revisione contabile, ad esempio i rischi di fallimento o frode di alto livello;
- nell'individuare e valutare i rischi di errori significativi nel bilancio a causa di frodi e testare le frodi in relazione ai rischi di audit;
- informazioni passate di un'azienda o risultati di audit passati possono essere utilizzati dai revisori per identificare i rischi di frode e lo sforzo diretto finalizzato al rilevamento di frodi;
- la SEC sta effettuando investimenti in *Big Data* per monitorare gli eventi di mercato, ricercare frodi e identificare fallimento degli audit; in particolare ha annunciato la costruzione della *Microcap Fraud Task Force* per indagare sulle frodi, la quale potrebbe essere utilizzata dai revisori per identificare attività fraudolente o ad alto rischio (Cao, Chychyla, Stewart, 2015).

Anche Alles, Gray, (2016) introducono degli importanti vantaggi associati all'uso dei *Big Data*:

- Arricchiscono fonti di dati per identificare potenziali attività fraudolente: difficile per il truffatore modificare tutte le transazioni non finanziarie a monte per coprire le frodi sui rendiconti finanziari. Ad esempio, il riciclaggio di denaro basato sul commercio può essere rilevato confrontando le fatture con il peso

effettivo dei container di spedizione. Alcuni dati potenzialmente preziosi potrebbero non essere disponibili a causa di considerazioni sulla privacy;

- L'analisi di tutti i dati aumenta la probabilità di scoprire bandiere rosse, “*smoking guns*,”<sup>10</sup> e valori anomali sospetti: la frode rappresenta una percentuale molto piccola delle transazioni e potrebbe essere facilmente non inclusa nei piccoli campioni tradizionalmente selezionati dagli auditor.

Inoltre anche Earley (2015) individua quattro principali vantaggi derivati dall'utilizzo dei *Big Data* negli audit:

- Gli auditor possono testare un numero maggiore di transazioni rispetto a quanto non facciano ora;
- La qualità dell'audit può essere aumentata fornendo maggiori transazioni sui processi dei clienti;
- Le frodi saranno più facili da rilevare perché i revisori possano sfruttare gli strumenti e la tecnologia che già utilizzano;
- I revisori possono fornire servizi e risolvere problemi per i propri clienti che vanno oltre le attuali capacità utilizzando dati esterni per informare i controlli (Earley, 2015).

La rilevazione di frodi e la quantificazione dei rischi sono identificati come principali vantaggi dell'analisi dei *Big Data* (Brown-Liburd, Issa, Lombardi, 2015). Ciò può essere attribuito ai requisiti normativi contenuti nell'ISA 240, secondo cui i revisori dimostrano maggiore rigore nella valutazione dei fattori di rischio di frode. Da questo punto di vista i *Big Data* sono visti come quel mezzo per soddisfare l'imperativo normativo in aree di interesse pubblico. Curtis e Turley (2007), ad esempio, sostengono che, alla fine degli anni '90, le più grandi società di revisione del Mondo hanno compiuto sforzi significativi per far percepire al pubblico il modello di *audit* come una grande innovazione in grado di migliorare l'efficacia dell'*audit* e il modo di riconoscere i rischi di frodi e fallimenti delle imprese allo stesso tempo, nonostante sostengano che la tecnologia potrebbe essere utilizzata per ridefinire l'audit e facilitare l'identificazione di offrire valore aggiunto ai clienti, migliorando lo status e la redditività del revisore dei conti (Salijeni, Samsonova-Taddei, Turley, 2019).

---

<sup>10</sup> Prove schiaccianti.

Alla riunione del *Public Company Accounting Oversight Board (PCAOB)*<sup>11</sup> e della *Standing Advisory Group (SAG)*<sup>12</sup> nel novembre 2014, in cui il rilevamento delle frodi da parte dei revisori è stato oggetto di tre sessioni del panel, l'argomento principale era come i *Big Data* possano essere utilizzati nel rilevamento delle frodi. Il punto di accordo era che i *Big Data* permettessero il rilevamento di frodi in quanto strumenti software che consentono ai revisori di analizzare in modo efficiente grandi serie di dati e che possono essere applicati a costi molto bassi dalle società di revisione (AICPA, 2014). Questi strumenti, noti come tecniche di audit assistite dal computer o CAAT, non sono una novità per le società di revisione, ma il loro uso è stato limitato, a causa della mancanza di accettazione da parte del personale di audit (Curtis, Payne, 2014) ma la maggiore disponibilità di dati dei clienti unita alla maggiore pressione per competere mediante l'uso dei *Big Data* con altre società di revisione, può cambiare l'atteggiamento dei revisori nei confronti dell'uso dei CAAT per rilevare le frodi. Ad esempio, come osservato da McGinty (2014), i revisori utilizzano sempre più, strumenti CAAT come la legge di *Benford*, un principio matematico che può essere applicato ai set di dati, che si è dimostrato efficaci nell'identificazione di transazioni fraudolente (Earley, 2015).

Un importante flusso di ricerca è incentrato sulla modellizzazione della frode, che può aiutare i revisori a valutare il rischio di frode (Bell, Carcello, 2000) quando conducono valutazioni del rischio. La sezione 200 della Dichiarazione sugli standard di revisione n. 122/123 richiede che i revisori esterni ottengano ragionevole certezza sul fatto che i bilanci nel loro insieme siano esenti da errori significativi, dovuti a frode o errore (AICPA, 2011). Adottando modelli contemporanei di *Big Data*, i revisori potrebbero fornire questa garanzia, nonostante il dibattito sul significato esatto di "ragionevole certezza" (Hogan, Rezaee, Riley, Velury, 2008).

La frode è una preoccupazione sostanziale per le organizzazioni e le economie di tutto il mondo. L'Associazione degli esaminatori di frode certificati (2016) stima che l'organizzazione tipica perde ogni anno il 5% delle entrate per frode. Applicando questo

---

<sup>11</sup> società senza scopo di lucro creata nel 2002 per supervisionare gli audit delle società pubbliche e di altri emittenti al fine di proteggere gli interessi degli investitori e promuovere l'interesse pubblico nella preparazione di informative di audit accurati e indipendenti.

<sup>12</sup> Il SAG include revisori, investitori, membri del comitato di revisione, dirigenti di società pubbliche e altri. Il SAG si riunisce due o tre volte all'anno ed è presieduto dal revisore capo del PCAOB e dal direttore degli standard professionali.

al Prodotto mondiale lordo per il 2014, la perdita globale di frodi ammonta a quasi 4 trilioni di dollari USA. Questi numeri hanno spinto i ricercatori a considerare l'applicazione di tecniche di *Big Data* per il rilevamento, la previsione e la prevenzione delle frodi (Gepp, Linnenluecke, O'Neill, Smith, 2018).

Poiché gran parte dei contenuti dei *Big Data* possono essere separati sia fisicamente che concettualmente dai dati contabili, è probabile che i truffatori non siano in grado di manipolare tutti gli elementi dei *Big Data* applicabili per mascherare le loro frodi. A causa dei contenuti sostanziali dei *Big Data* e del concetto di campionamento al 100% (che analizza l'intera popolazione), la scoperta di bandiere rosse e altri valori anomali sospetti è notevolmente aumentata. Ci sono molti altri fattori coinvolti, ma l'analisi dei *Big Data* ha chiaramente il potenziale per rilevare frodi ingenti (Alles, Gray 2016).

Con l'avvento dei *Big Data*, la quantità e la diversità delle informazioni è aumentata e, di conseguenza, i *Big Data* offrono agli auditor un enorme potenziale per migliorare l'efficienza e l'efficacia di un incarico di revisione. Ad esempio, l'analisi delle transazioni in contanti per garantire la conformità alle normative sul riciclaggio di denaro è un esempio di un'area ad alto rischio in cui i revisori possono utilizzare l'analisi dei *Big Data* per concentrarsi su transazioni sospette. In questo scenario la regola è che per qualsiasi pagamento che superi un importo specificato sia necessaria un'approvazione speciale. Per evitare la necessità di passare attraverso il processo di ottenimento di quest'approvazione, alcuni utenti possono ricorrere a mantenere l'importo della transazione appena al di sotto della soglia o a dividere l'importo in più transazioni, un fenomeno noto come "pagamenti divisi". Tali transazioni potrebbero non violare alcun controllo interno, ma utilizzi frequenti potrebbero richiedere ulteriori indagini sugli investimenti per garantire la legittimità di tali transazioni. Questo scenario illustra che, scoprendo modelli che sarebbero altrimenti sconosciuti, l'analisi dei dati utilizzata per estrarre informazioni da grandi volumi di dati può aiutare gli auditor a identificare aree ad alto rischio in cui dovrebbero concentrare i loro sforzi investigativi (Brown-Liburd, Issa, Lombardi, 2015). Un altro esempio di area ad alto rischio potrebbe essere quella costituita dai beni digitali, in quanto richiedono ingenti investimenti in attività immateriali ma la loro valutazione offre maggiore libertà ai contabili che possono modificare le voci di bilancio in misura tale da non far riflettere i valori effettivi. Per i revisori, a volte, è difficile misurare le valutazioni dei contabili e, quando le loro opinioni

differiscono, dare una giustificazione; per questo l'attestazione del revisore potrebbe diventare meno informativa per i destinatari della revisione (Tiberius, Hirth, 2019).

È possibile che i consigli di amministrazione e gli utenti del bilancio impongano ai revisori dei conti uno standard più elevato di individuazione delle frodi e responsabilità per la scoperta di errori nel bilancio. Ad esempio, come osservato da Gray e Debreceeny (2014, p. 378), sotto l'*auditing* tradizionale, il revisore ha una difesa per non scoprire frodi se il campione selezionato risulta privo della "smoking guns" che indicherebbe altrimenti la frode: *"Data mining can be considered the equivalent to taking a 100% sample. If the smoking gun is in that sample, but the auditors missed it, then the auditors no longer have their traditional industry-practice defense."* Cioè Il *data mining* può essere considerato equivalente al prelievo di un campione del 100%. Se la prova evidente si trova in quel campione, ma i revisori l'hanno persa, i revisori non hanno più la loro tradizionale difesa della pratica industriale (Earley, 2015).

I *Big Data* possono offrire supporto quando le prove di audit tradizionali sono carenti, come potrebbe essere in un caso di frode. Ottenere prove di frode è difficile perché le prove di componenti legate alla motivazione e alla razionalizzazione sono correlate allo stile di vita, alla condotta e alla moralità di un individuo (SAS n. 99, AICPA 2002), nessuna delle quali è necessariamente osservabile. La valutazione delle e-mail può essere particolarmente utile per identificare la motivazione di una persona e il probabile miglioramento (Brown-Liburd, Issa, Lombardi, 2015). Condurre un'analisi del sentiment delle e-mail aziendali potrebbe aiutare un revisore a comprendere la società sottoposta a revisione e rivelare le aree a maggior rischio. Ad esempio, un sentiment di posta elettronica incoerente all'interno di un'unità aziendale potrebbe indicare disarmonia interna e segnalare che i controlli interni sono stati violati o che si è verificata una frode. Quando il sentiment di posta elettronica a livello di senior management di un'organizzazione è positivo, ma diventa negativo a livelli inferiori, può indicare che i dipendenti sono consapevoli e infelici del fatto che la direzione abbia commesso violazioni del controllo o frodi (Gepp, Linnenluecke, O'Neill, Smith, 2018). Questo tipo di rilevazione potrebbe però incorrere in una violazione della privacy, nonostante l'attività porti all'individuazione tempestiva delle frodi (La Torre, Botes, Dumay, Odendaal, 2019). L'uso dei *Big Data* implica l'estrazione d'informazioni, per l'analisi da una popolazione, estremamente ampia di dati da più fonti non finanziarie che i revisori non sono abituati a dover raccogliere e analizzare durante lo svolgimento di una verifica. Mentre i



tradizionali strumenti di analisi dei dati come le tecniche di *audit* assistito dal computer (CAAT) hanno dimostrato di essere efficaci (Dowling, Leech 2007), sono essenzialmente strumenti di estrazione dei dati che consentono ai revisori di eseguire analisi dei dati mediante query. Con i CAAT spetta al revisore identificare le anomalie in base ai parametri definiti per analisi dei dati più avanzate (ad es. *clustering*), che analizzano set di dati più grandi per identificare modelli e anomalie, che il revisore deve quindi approfondire (Brown-Liburdi, Issa, Lombardi 2015).

La capacità di sfruttare appieno i vantaggi dei *Big Data* risiede nelle tecniche di analisi dei dati più avanzate (ad es. *Clustering*, reti neurali), che potenzialmente migliorano l'efficacia dell'audit. Gli strumenti di analisi dei dati utilizzati per analizzare i *Big Data* offrono ai revisori la possibilità di incorporare e utilizzare sia i dati strutturati (ad es., contabilità generale o dati di transazione) sia quelli non strutturati (ad es. comunicazioni e-mail, sensori Wi-Fi, tag elettronici, campi di freetext nei database) identificare potenziali anomalie transazionali (ad es. erogazioni non autorizzate), modelli di comportamento (ad es. pagamenti divisi per bypassare il limite di transazione) e tendenze (ad es. aumento delle transazioni fraudolente prima di una grande vacanza). Ad esempio, la valutazione del rischio di frode è un giudizio molto complesso e soggettivo che i revisori sono tenuti a formulare su ogni audit (Brown-Liburdi, Issa, Lombardi, 2015). Un altro vantaggio dei *Big Data* nella revisione contabile è la possibilità di utilizzare dati non finanziari (NFD) e dati esterni per informare meglio la pianificazione della revisione contabile (in particolare nella valutazione del rischio) e per controllare in modo più efficace quelle aree che richiedono giudizio, come la valutazione o la continuità aziendale (Earley, 2015).

A differenza di queste tecniche di dati più avanzate, i metodi di *audit* tradizionali non sono sempre stati molto efficaci nell'identificazione dei rischi di frode, (ad esempio, l'uso di liste di controllo standard per i rischi di frode e programmi di pianificazione standard) (Pincus 1989; Eining, Jones, Loebbecke 1997; Asare, Wright 2004).

Al contrario, strumenti tecnologicamente avanzati (ad es. *Data mining*) e analisi dei dati (ad es. Modellazione predittiva) si sono rivelati strumenti efficaci che possono essere utilizzati nell'analisi e nella valutazione dei *Big Data* nella valutazione dei rischi di frode (Humpherys, Moffitt, Burns, Burgoon, Felix 2011; Bochkay, Levine 2013), (ad esempio, le correlazioni negative tra misure non finanziarie e finanziarie della performance aziendale potrebbero essere indicative di manipolazione delle informazioni finanziarie).

Tuttavia, anche nell'ambiente dei *Big Data* esistono limitazioni che non possono essere superate solo con strumenti avanzati. Le decisioni prese sulla base delle informazioni derivate dai *Big Data* implicano ancora interpretazione e giudizio, ad esempio, sebbene gli strumenti tecnologici possano identificare modelli, è il revisore che deve analizzarli e valutarli.

Un esempio di strumento avanzato è stato utilizzato in campo medico e tratta di operazioni di *data mining* per scoprire nuove tendenze e associazioni che potrebbero migliorare le funzioni diagnostiche e terapeutiche per favorire i migliori risultati dei pazienti (Martin 2013). Sono strumenti che possono essere applicabili all'ambiente di audit e possono essere adottati dai revisori per consentire loro di elaborare meglio l'output dei dati al fine di identificare in modo più efficace bandiere rosse o valori anomali.

I ricercatori hanno anche utilizzato l'analisi del modello e dei collegamenti (vale a dire, valutazione delle relazioni tra oggetti come persone, organizzazioni, transazioni, ecc.) per rilevare frodi (Hughes 2013), particolarmente importante in un contesto di audit in cui la valutazione del rischio di frode è un componente principale del processo. Specificamente correlato al contesto dell'audit, Lombardi (2012) ha limitato l'incorporazione di informazioni irrilevanti nel processo decisionale facendo in modo che i revisori meno esperti utilizzino un sistema qualificato (una forma di ricerca di analisi dei collegamenti che utilizza regole di decisione basate su conoscenze specialistiche utilizzando dati strutturati) nel processo della valutazione del rischio di frode. Nell'ambiente di audit, ad esempio, il processo di valutazione del rischio di audit comporta generalmente il riconoscimento di modelli nei dati (ad esempio, anomalie e incoerenze dei dati complessi) che possono suggerire errori o frodi (Libby 1985; Bedard, Biggs 1991a; Coakley, Brown 1993) (Brown-Liburd, Issa, Lombardi, 2015). Nel momento in cui tutti i dati vengono elaborati attraverso i sistemi analitici del revisore e non si riesce a identificare frodi o errori, esiste il rischio che il revisore venga considerato "*second-guessed*" cioè venga messo in discussione il suo lavoro ed è sempre facile per gli altri poi identificare gli indicatori che il revisore ha mancato e collegare i punti. Questo non è un problema completamente nuovo, ma i revisori hanno tradizionalmente basato il loro lavoro su campioni e si ammette che esiste un rischio statistico di non identificare frodi o errori, allo stesso tempo, una modifica all'analisi dei

*Big Data* potrebbe identificare frodi o errori che mancavano in passato (Cao, Chychyla, Stewart, 2015).

Come diceva Norris (2011): "*To the auditing industry, the fact that investors tend to blame auditors when frauds go undetected reflects unrealistic expectations, not bad work by the auditors. The rules say auditors are supposed to have a 'healthy degree of skepticism, but not to detect all frauds.'*" Cioè per il settore della revisione contabile, il fatto che gli investitori tendano a incolpare i revisori quando le frodi non vengono individuate riflette aspettative non realistiche, non un cattivo lavoro da parte dei revisori. Secondo le regole, i revisori dovrebbero avere un sano grado di scetticismo, ma non rilevare tutte le frodi (Alles, Gray, 2016).

Le recenti tendenze della tecnologia dimostrano che i revisori possono essere formati per superare le difficoltà con il riconoscimento di schemi. O'Donnell e Perkins (2011) scoprirono che i revisori che utilizzano uno strumento di pensiero sistematico, si concentrano maggiormente sugli schemi diagnostici delle fluttuazioni dei conti e valutano correttamente il rischio di errori a livelli più alti. Inoltre, Selby (2011) rileva che i revisori che hanno una conoscenza delle procedure dei controlli automatizzati, sono in grado di interpretare meglio i modelli di rischio nelle prove di controllo automatizzato.

Un problema importante è quindi l'adozione di adeguati strumenti di analisi dei dati. In effetti, decidere quale strumento utilizzare avrà un ruolo importante nell'utilizzo dei *Big Data*. Mediamente un sondaggio di 325 intervistati di professionisti della gestione dei dati, Russom (2011) classifica l'analisi dei *Big Data* in quattro gruppi principali a seconda della loro potenziale crescita (di utilizzo) e impegno organizzativo, ad esempio, se la popolarità dello strumento aumenterà o diminuirà, e la probabilità che l'azienda si attenga allo strumento specifico. Il primo gruppo dovrebbe aumentare di popolarità (forte crescita potenziale) e comprendere modelli predittivi, tecniche di apprendimento automatico, intelligenza artificiale, analisi statistiche e tecniche di visualizzazione. Esempi di questo gruppo includono analisi in tempo reale che analizzano i dati per aggiornare i *dashboard* (pannelli di controllo) utilizzati dalla direzione o dai revisori al fine di identificare i problemi in tempo reale. In questo gruppo sono inclusi anche strumenti di estrazione del testo, che stanno guadagnando popolarità grazie alla loro applicabilità a una vasta gamma di problemi, come la valutazione del rischio e la frode (Russom 2011).

Il secondo gruppo comprende *data warehouse* e sistemi di gestione di database dedicati (DBMS<sup>13</sup>). A causa della maggiore disponibilità di una varietà di piattaforme, è probabile che queste analisi sperimentino un tasso di adozione più elevato. Le aziende possono scegliere tra una varietà di prodotti, molti dei quali vengono forniti con analisi integrate (o analisi all'interno del database) che possono facilitare il lavoro dei revisori nell'esame dei dati. Il terzo gruppo è relativamente nuovo e non è ben noto agli *auditor*, nonostante il vantaggio di sfruttare il calcolo. Questa funzionalità è particolarmente importante in seguito alla globalizzazione, in cui i dati acquisiti sono sparsi in tutto il mondo. Tali strumenti consentono ai revisori di gestire dati di vario tipo (ad es. Testo, finanziario) e provenienti da varie fonti (e-mail, ERP). Infine, l'ultimo gruppo è costituito dagli strumenti attualmente utilizzati dalla maggior parte delle aziende e che dovrebbero svanire nel tempo a causa della loro limitata scalabilità, come i tradizionali sistemi di gestione dei database (DBMS) progettati per dati strutturati tradizionalmente (Russom 2011).

Per risolvere una parte dei problemi dell'introduzione dei *Big Data*, le società di revisione potrebbero avviare collaborazioni con società di soluzioni *Big Data*, come *Data Alliance Collaborative*, per creare metodi analitici che riducano i costi migliorando al contempo i risultati (Conn 2013). Questa collaborazione risparmierebbe tempo e costi sostanziali adottando uno strumento già funzionale che viene utilizzato con successo in altri settori. I revisori potrebbero quindi concentrarsi maggiormente sull'esecuzione e valutazioni delle informazioni pertinenti estratte dai *Big Data*, anziché dedicarsi allo sviluppo e all'impiego di metodi e strumenti per analizzare i dati non strutturati o strutturati (Brown-Liburd, Issa, Lombardi, 2015). Altra possibilità è che possano esternalizzare la maggior parte dei *Big Data* ai centri offshore, i quali forniscano ai revisori l'output dei *Big Data* per effettuare eventuali ulteriori procedure di verifica dei controlli. Un'altra possibilità prevede la creazione di strumenti che automatizzino il più possibile il processo e la categorizzazione delle anomalie in modo che i revisori possano esprimere il giudizio affrontando il minor numero di anomalie identificate da questi strumenti (Earley, 2015).

Per quanto riguarda le anomalie, indipendentemente che siano o meno falsi positivi, spesso portano a un aumento del volume del lavoro che devono svolgere gli auditor e quindi costi più elevati; la presenza di falsi positivi riduce la probabilità che i *Big Data*

---

<sup>13</sup> database management systems.

vengano incorporati nell'*audit* (Salijeni, Samsonova-Taddei, Turley, 2019). Una delle principali fonti di affidabilità dei *Big Data* è che è estremamente difficile manomettere i dati, date le loro ampie dimensioni, specialmente quando i dati sono generati in tempo reale da fonti esterne ma la principale preoccupazione è la loro qualità. L'affidabilità diminuisce quando il rumore nei *Big Data* porta a un sovraccarico di falsi positivi. Inoltre, i *Big Data* provenienti dai siti Web dei *social media*, come *Twitter*, potrebbero essere distorti perché i loro utenti non rappresentano l'intera popolazione dei clienti (Yoon, Hoogduin, Zhang, 2015).

Inoltre, i falsi positivi (ovvero le anomalie consolidate che si rivelano operazioni appropriate) continuano a rappresentare una preoccupazione significativa delle società di revisione, per quanto riguarda l'adozione degli approcci dei *Big Data* (Wang, Cuthbertson 2015) e resta da vedere se gli strumenti automatizzati possono eliminare falsi positivi o ridurli a quantità gestibili. Troppi falsi positivi hanno il potenziale di focalizzare l'attenzione dei revisori in aree che alla fine non sono a rischio di errori (Earley, 2015).

Indipendentemente dall'approccio adottato, l'ambiente dei *Big Data* farà sì che il giudizio del revisore svolga un ruolo molto più significativo rispetto al controllo basato su campioni, a causa del potenziale elevato numero di anomalie da valutare. In questo scenario, i revisori dovranno sviluppare una forte comprensione di ciò che costituisce una corretta contabilità nel contesto delle attività dei loro clienti al fine di eseguire questa valutazione (Earley, 2015). Ad esempio, se un consulente di terze parti utilizza strumenti di *data mining* per estrarre importanti segnali di frode dai *Big Data*, i revisori possono quindi dedicare tempo a concentrarsi sulla valutazione del livello di rischio di frode per ogni segnale estratto. Questo approccio probabilmente migliorerebbe le valutazioni del rischio di frode, poiché solo le informazioni pertinenti dei *Big Data* vengono identificate da uno strumento di analisi dei dati (Brown-Liburd, Issa, Lombardi, 2015).

Gli studiosi mostrano che hanno usato tecniche di *Big Data* per modellare il verificarsi di frode come una variabile binaria dipendente, che tratta implicitamente tutte le frodi al medesimo modo. Anche se il costo della frode varia notevolmente da un caso all'altro e ha evidenti implicazioni economiche, pochissimi studi hanno modellato il suo costo.

Esiste anche un'opportunità per i modelli di frode di trarre vantaggio dal fatto che spesso si verificano accordi tra più autori di reati in casi di frode. Free e Murphy (2015)

concludono che la natura sociale della frode può aiutare a identificare le caratteristiche distintive, in quanto queste funzionalità potrebbero essere incorporate nei modelli di frode per migliorarne l'accuratezza.

I revisori esterni possono migliorare le loro valutazioni del rischio di frode utilizzando modelli di frode di *Big Data* basati su modelli di regressione standard, come il noto modello di frode F-score basato sulla regressione logistica (Dechow, Ge, Larson, Sloan, 2011). Questi modelli di frodi sui *Big Data* sono sviluppati utilizzando i dati delle frodi passate. Offrono preziose informazioni ai revisori perché le ricerche precedenti hanno rivelato che essi spesso hanno poca esperienza reale di frode (Humpherys, Moffitt, Burns, Burgoon, Felix, 2011). Tuttavia, i revisori tendono a essere avversi a fare affidamento sui modelli in fase rilevazione delle frodi (Eining, Jones, Loebbecke, 1997), quindi vi è un'opportunità per le ricerche future di studiare come utilizzare al meglio i modelli di frode sui *Big Data* in collaborazione con l'esperienza dei revisori.

I revisori interni invece potrebbero utilizzare questi modelli per attirare l'attenzione su situazioni che richiedono un'indagine, mentre i revisori forensi potrebbero utilizzare questi modelli per determinare la probabilità che si siano verificate frodi, al fine di fornire una conferma iniziale (Gepp, Linnenluecke, O'Neill, Smith, 2018).

L'AICPA ha redatto una dichiarazione di audit volta a rilevare le frodi (SAS n. 99). Lo standard richiede specificamente una sessione di brainstorming che deve essere tenuta dai revisori per identificare i rischi legati alla frode. Più recentemente, l'idea del *brainstorming* è stata aggiunta a più sezioni degli standard di auditing (Tang Karim, 2019).

La Dichiarazione sugli standard di revisione n. 99 (SAS 99) è un insieme di norme stabilite nel 2002 dopo il verificarsi degli scandali contabili. La dichiarazione mira a prevenire e individuare in modo più efficace attività fraudolente. Uno dei punti salienti di SAS 99 è il requisito di una sessione di *brainstorming* tenuta dai membri del team di audit. Da allora, gli standard sono stati aggiornati e l'idea di implementare una sessione di *brainstorming* è stata mostrata in diverse parti degli standard AICPA (AU-C 240 e AU-C 315) e PCAOB (AS 2110). Secondo AU-C 240, il contenuto delle sessioni di *brainstorming* dovrebbe includere il verificarsi di potenziali errori significativi, i metodi che la direzione potrebbe utilizzare per commettere frodi e la possibilità di appropriazione indebita di risorse.

L'integrazione dell'analisi dei *Big Data* fornisce una soluzione per migliorare le prestazioni delle sessioni di *brainstorming*. Innanzitutto, i *Big Data* possono ampliare la base d'informazioni utilizzata. Combinando o aggregando diversi tipi d'informazioni tramite strumenti di *Big Data*, i revisori possono avere accesso a un database che contiene sia le informazioni finanziarie (es. Record contabili) che non finanziarie (es. Notizie sulla gestione, verbali delle riunioni del consiglio di amministrazione, dettagli del contratto, ecc.) dell'azienda cliente. In secondo luogo, i *Big Data* possono migliorare il contenuto delle informazioni. Quando conducono procedure analitiche, i revisori possono confrontare efficacemente i dati nel tempo e nei settori per identificare rapidamente le anomalie. Un campione più ampio di dati (o l'intera popolazione) aumenterà anche l'accuratezza dei modelli di previsione, pertanto, i *Big Data* possono generare risultati affidabili che indicano più precisamente i rischi di frode. Infine, possono facilitare le comunicazioni tra i membri del team di revisione o tra i predecessori e i revisori successivi. Ad esempio, durante le sessioni di *brainstorming*, gli auditor possono utilizzare dispositivi elettronici per registrare i loro pensieri mentre leggono i commenti degli altri membri contemporaneamente (Tang, Karim, 2019), registrare discussioni sulle frodi, tracciare la catena di pensieri e stabilire possibili scenari, possono scrivere commenti più lunghi che includono foto, diagrammi di flusso e video per esprimere le proprie idee. I dispositivi possono essere utilizzati per registrare simultaneamente tutti i commenti dei revisori e presentarli sulla stessa schermata, possono essere programmati per combinare i dati non strutturati e raggruppare i commenti dei revisori in categorie. Inoltre, possono raccogliere i commenti sia dai predecessori che dagli attuali revisori e attingere a precedenti casi di frode verificatisi nella vita reale. Ciò consente ai revisori di tracciare il modello di pensiero di potenziali truffatori e costruire scenari ipotetici di frode (Tang, Karim, 2019).

Inoltre, i *Big Data* possono anche incorporare le competenze del settore dei singoli revisori visualizzando selettivamente sul monitor informazioni pertinenti (ad esempio notizie, indice del settore, concorrenti) per ispirare nuove idee. Nel complesso, l'applicazione dell'analisi dei *Big Data* nelle sessioni di *brainstorming* consente ai revisori di utilizzare dati non strutturati e analizzare i fattori di frode strettamente correlati al triangolo delle frodi (Tang, Karim, 2019).

Carpenter (2007) conclude che i revisori che effettuano *brainstorming* possono generare idee nuove e di qualità sul rilevamento delle frodi e possono fare valutazione del rischio

più elevata rispetto ai singoli revisori. Brazel et al. (2010) affermano che i fattori di rischio di frode (incentivi, opportunità e razionalizzazione) possono indicare più efficacemente la probabilità di frode quando il *brainstorming* è di alta qualità.

Lynch et al. (2009) mostrano che sessioni di *brainstorming* mediate da computer migliorano l'efficacia della valutazione del rischio di frode ma il *brainstorming* elettronico può mitigare preoccupazioni come blocco della produzione e apprensione alla valutazione e può rafforzare la sinergia durante le interazioni (Dennis e Valacich, 1993). Inoltre, Smith et al. (2012) affermano che le prestazioni superiori del *brainstorming* elettronico sono dovute principalmente alla maggiore concentrazione delle attività e ai commenti più lunghi fatti dai revisori. In particolare, i gruppi basati su computer e i sistemi di supporto di gruppo (GSS) hanno dimostrato forti prestazioni in compiti relativi alla generazione di idee (Valacich et al., 1994; Fjermestad, Hiltz, 1998).

In contrapposizione la letteratura ha anche mostrato alcuni benefici del *brainstorming* faccia a faccia. Ad esempio, Cockrell e Stone (2011) sostengono che il *brainstorming* faccia a faccia incoraggi discussioni più approfondite che portano a prestazioni migliori rispetto al formato elettronico, come Brazel et al. (2004) sostengono che la revisione della carta di lavoro di audit faccia a faccia è associata a una maggiore responsabilità e ad un giudizio di qualità superiore da parte dei preparatori rispetto alla revisione in modalità elettronica. Nel complesso, il *brainstorming* facciale sembra risentire maggiormente della perdita di processo, in particolare del blocco della produzione, mentre il *brainstorming* elettronico potrebbe tradursi in un dialogo e un giudizio di bassa qualità.

L'analisi dei *Big Data* può essere utile in questa dimensione in quanto incorpora dati non strutturati e fornisce risultati più affidabili. Inoltre affronta le preoccupazioni sia nel *brainstorming* faccia a faccia che elettronico. Come accennato in precedenza, l'efficacia del *brainstorming* può essere compromessa a causa del blocco della produzione e della mancanza di discussioni approfondite. L'uso dei *Big Data* può, almeno in una certa misura, mitigare questi problemi e migliorare l'efficacia del rilevamento delle frodi. Possono anche aumentare la qualità dell'*audit* grazie alla sua capacità di abilitare l'*audit* basato sulla popolazione rispetto al campione (Ramlukan, 2015). Mentre l'applicazione dei *Big Data* nella pratica contabile e di revisione era stata introdotta in precedenza (Tang, Karim, 2017), l'attenzione alle sessioni di *brainstorming* rimane indiscussa e potrebbe generare implicazioni utili. Una parte fondamentale della sessione di



*brainstorming* è la revisione e l'analisi delle informazioni preliminari del cliente nel quadro del triangolo delle frodi, pertanto le informazioni dovrebbero essere presentate in vari formati che possano indicare efficacemente i fattori di rischio di frode.

I *Big Data* possono aiutare i revisori a esaminare le relazioni non più in corso, in particolare quelle tra dirigenti e membri del comitato di revisione. Le informazioni derivate dai social media possono aiutare i revisori a identificare gli appuntamenti o le nuove posizioni ottenute attraverso la rete personale, il che spesso porta a attività fraudolente. Con l'aiuto della tecnologia *Big Data*, le sessioni di *brainstorming* possono combinare le informazioni degli informatori con i dati in altri formati, mantenendo la riservatezza e aumentando la completezza delle prove. In breve, i *Big Data* forniscono una base d'informazioni più ampia e più ricca di risorse che consente ai revisori di tradurre in modo efficiente gli elementi probativi in fattori di rischio di frode. L'integrazione di dati non strutturati migliora anche la veridicità degli elementi probativi in quanto i dati raccolti in quantità così grande e da fonti molto diverse offrono prove più complete rispetto ai dati tradizionali e sono soggetti a una minore gestione da parte della direzione.

I *Big Data* possono migliorare le prestazioni delle procedure analitiche, ottenendo così risultati più approfonditi e affidabili per il processo decisionale. PCAOB (2007) afferma che le prestazioni delle procedure analitiche possono essere rafforzate se i dati analizzati sono soggetti a meno manipolazioni. Raccogliendo dati grezzi tempestivi da fonti reali, è possibile presentare agli auditor informazioni più affidabili, migliorando così la pertinenza delle idee generate durante il processo di *brainstorming*, cioè, gli strumenti di analisi dei *Big Data* possono contribuire in modo significativo alle sessioni di *brainstorming* se sono progettati per fornire un feedback tempestivo e accurato.

Lo standard ISA 315 che fornisce indicazioni sulla valutazione del sistema di controllo interno del cliente e l'ISA 240 che indica la responsabilità del revisore in materia di frode in una revisione richiederanno un'attenzione particolare, poiché la frode può diventare più pronunciata a causa del volume delle transazioni; infatti Appelbaum et al. (2017) indicano che, poiché la gestione ha la capacità di ignorare i controlli interni, la frode può aumentare in un ambiente di *Big Data* (La Torre, Botes, Dumay, Odendaal, 2019).

I *Big Data* possono essere rivisti prima o dopo aver esaminato gli elementi probativi tradizionali. In alcune grandi aziende, i dipartimenti di *Internal Auditing* richiedono

l'analisi e la revisione dei *Big Data* durante la fase di pianificazione prima dell'esame delle prove di audit più tradizionali. I professionisti sostengono che l'esame delle visualizzazioni dei *Big Data* prima delle prove tradizionali consente ai revisori di identificare modelli utili che miglioreranno la loro interpretazione e analisi delle prove di verifica più tradizionali. Altri professionisti sostengono che le visualizzazioni di *Big Data* dovrebbero essere utilizzate solo per integrare altre prove di audit e che i *Big Data* dovrebbero essere rivisti dopo l'esame di prove di audit più tradizionali. Mentre i professionisti hanno prospettive diverse riguardo a quando le prove sui *Big Data* dovrebbero essere riviste durante l'incarico di revisione, non ci sono ricerche attuali, conosciute che indagano i potenziali effetti del tempismo sul processo decisionale del revisore (Rose, Rose, Sanderson, Thibodeau, 2017).

### **3.2.3 Osservazioni finali relative ai *Big Data* e frode nella revisione**

I *Big Data* svolgeranno un ruolo importante nell'*auditing* perché integrano le prove tradizionali con informazioni sufficienti, affidabili e pertinenti e saranno utilizzati per valutare elementi probativi interni e offriranno agli auditor opportunità uniche.

Le aziende stanno investendo in *Big Data* per migliorare il proprio processo decisionale e si aspettano che i revisori possano sfruttarli per migliorare anche l'efficacia e l'efficienza degli *audit*.

Tiberius, Hirth, (2019) esamina i cambiamenti nelle pratiche di auditing attesi dai professionisti tedeschi entro i prossimi cinque o dieci anni a causa dell'entrata dei *Big Data* e quindi della digitalizzazione del sistema di *auditing*. In particolare le previsioni principali che essi fanno sono:

- la quantità di attività immateriali (ad es. Software) nei bilanci delle società sarà molto più alta di quella odierna. Con una maggiore flessibilità di valutazione, gli audit diventeranno meno informativi per gli utenti;
- gli utenti della revisione si fideranno di più delle procedure di audit automatizzate che di quelle manuali;
- i clienti non considereranno gli attuali modelli dei prezzi di audit appropriati, poiché una maggiore automazione eroderà le tasse, grazie alla riduzione della forza lavoro;
- esisterà un sostanziale divario normativo tra la nuova realtà aziendale digitale e gli standard di audit, in quanto in molti casi il progresso tecnologico è più rapido della legislazione e della regolamentazione;

- i criteri di contabilità e audit saranno stabili dall'innovazione tecnologica;
- i cambiamenti tecnologici sostituiranno la maggior parte delle società di revisione di piccola e media dimensione, in quanto dovranno sostenere investimenti in infrastrutture tecnologiche e nuove competenze;
- saranno richiesti elevati livelli di competenza IT e dati da parte degli auditor; a scapito delle tradizionali abilità di business la digitalizzazione aumenterà e i modelli di business dei clienti cambieranno costantemente .

Tuttavia la percezione degli utenti dell'audit possono essere disaccoppiate o addirittura opposte al progresso tecnologico effettivo, anche se i processi automatizzati fossero oggettivamente superiori a quelli manuali, gli esseri umani potrebbero comunque fidarsi e preferire i giudizi umani rispetto a quelli automatizzati e anonimi.

Esistono molte opportunità di utilizzare tecniche di *Big Data* nell'auditing, in particolare quando rigorose procedure analitiche sono combinate con tecniche di audit tradizionali e il giudizio di esperti, si potrebbe trarre vantaggio dal miglioramento dei recenti modelli di frode relativi ai *Big Data* in quanto le procedure di controllo automatizzato riducono gli errori umani; quindi in futuro per il controllo si potrebbero utilizzare procedure di controllo più automatizzate rispetto a quelle manuali.

### **3.3 Models: strumenti di *Big Data* utilizzati per la rilevazione della frode**

#### **3.3.1 Caratteristiche dei modelli di *Big Data***

*Big Data* è considerato il nuovo petrolio. Le aziende, i governi e le organizzazioni che sono in grado di estrarre questa risorsa avranno un enorme vantaggio rispetto a quelli che non lo fanno (Deloitte, 2012, pag. i). I *Big Data* sono costituiti da set di dati così voluminosi da non poter essere ragionevolmente analizzati utilizzando i tradizionali sistemi di gestione di database o programmi software (Enget, Saucedo, Wright, 2017).

L'automazione dell'analisi dei dati non è un fenomeno recente. In effetti, è stato articolato in vari settori sin dai primi anni '80. Un esempio pionieristico è stato un sistema esperto creato con l'obiettivo esplicito di consentire agli utenti inesperti di eseguire correttamente le routine di analisi della regressione (Gale, Pregibon 1982). In un altro esempio, il software è stato formulato per progettare ed effettuare valutazioni statistiche dei dati medici rilevanti (Blum 1983). Mentre in questo periodo si sta sviluppando un notevole interesse e si sta discutendo, sviluppando e implementando diversi tipi di sistemi formativi di esperti, sembra che ci sia comunque perplessità.

Tuttavia, con sviluppi che includono la continua evoluzione della tecnologia, una maggiore potenza di elaborazione e capacità di archiviazione, nonché l'emergere e la percezione dell'importanza dei *Big Data*, gli sforzi e l'entusiasmo per l'analisi automatizzata dei dati sono diventati sempre più salienti. Ad esempio, il lavoro relativo al sistema di controllo continuo proposto e inizialmente implementato per un aspetto specifico di un processo aziendale presso Bell Labs (Vasarhelyi, Halper 1991) si è ora evoluto in modo tale che il controllo continuo è previsto per una varietà di cicli economici. Nel prossimo futuro, questo paradigma potrebbe diventare la norma per tutte le aziende. In un'altra area, gli sforzi di ricerca sono dedicati all'automazione del processo di clustering in modo che i professionisti siano autorizzati a utilizzare efficacemente le tecniche di *data mining* in adempimento delle responsabilità professionali (Byrnes 2019).

I dati sono al centro dei sistemi di informazione contabile (AIS). I recenti sviluppi nella tecnologia dell'informazione (IT) hanno portato a un aumento senza precedenti della generazione, archiviazione e accessibilità dei dati per le aziende di ogni tipo. Una crescita così esplosiva di dati aziendali rilevanti è caratterizzata da una quantità crescente di dati non strutturati come testo, dati vocali e dati d'immagine (Guan, Levitan, Goyal, 2018).

Le più grandi società di contabilità stanno utilizzando software e altre tecnologie cognitive per identificare modelli di dati indistinguibili dall'occhio umano. In particolare, KPMG ha stipulato un contratto con IBM per utilizzare *Watson*, al fine di migliorare i servizi di audit e consulenza. *Watson* può elaborare grandi volumi di dati non strutturati e fornire approfondimenti significativi in inglese e altre sette lingue (Best, 2016; Claburn, 2016; IBM, 2016). Lynne Doughtie, presidente e CEO di KPMG, afferma che *“KPMG’s use of IBM Watson technology will help advance our team’s ability to analyze and act on the core financial and operational data so central to the health of organizations and the capital markets. In addition to the unprecedented possibilities for enhancing quality, the potential for cognitive and related technologies to help us pursue new business offerings is extraordinary”* (Lee, 2016). Vuole quindi sottolineare che l'utilizzo da parte di KPMG della tecnologia IBM *Watson* aiuterà a migliorare la capacità del team di analizzare e agire sui dati fondamentali, importanti per la salute delle organizzazioni e dei mercati dei capitali. Mentre le opportunità legate ai *Big Data* sono praticamente infinite, un sondaggio condotto su 2000 aziende ha rilevato che l'86% sta lottando per

trovare le informazioni sepolte dalla straordinaria quantità di dati insignificanti (Chartered Global Management Accountant (CGMA), 2014). Gli studi stimano che la domanda di analisi dei dati raddoppierà nel prossimo futuro, offrendo opportunità ai professionisti dell'informatica, della finanza e della contabilità. Il McKinsey Global Institute (2011) ha previsto una domanda accresciuta fino al 2018, affermando: *“The United States alone faces a shortage of 140,000 to 190,000 people with analytical expertise and 1.5 million managers and analysts with the skills to understand and make decisions based on the analysis of Big Data.”* Solo gli Stati Uniti devono affrontare una carenza di 140.000-190.000 persone con competenze analitiche e 1,5 milioni di manager e analisti con le capacità di comprendere e prendere decisioni basate sull'analisi dei *Big Data* (Fay, Negangard, 2017).

L'intelligenza artificiale è un'attitudine dimostrata dalle macchine, in contrasto con l'intelligenza naturale mostrata dall'uomo. Utilizzando le tecnologie più innovative, possiamo trovare nuove soluzioni di business e risolvere problemi che fino ad ora sembrano difficili da risolvere. I principali vantaggi generati da questi strumenti innovativi comprendono la riduzione del rischio di errore (in particolare l'errore umano); basso rischio di frode; automazione del sistema, enormi risparmi sui costi (aumentando l'efficienza e diminuendo gli errori), maggiore affidabilità nei report finanziari e flusso di lavoro ridotto. Gli economisti contemporanei hanno definito la digitalizzazione come il riallineamento o il nuovo investimento in tecnologia avanzata e modelli di business per coinvolgere in modo più efficace i clienti digitali in ogni punto di contatto nel ciclo di vita dell'esperienza del cliente (Solis, Littleton, 2017).

Di seguito vengono indicate tutte le sfide che devono affrontare gli utilizzatori di strumenti digitali, in questa era di importanti cambiamenti.

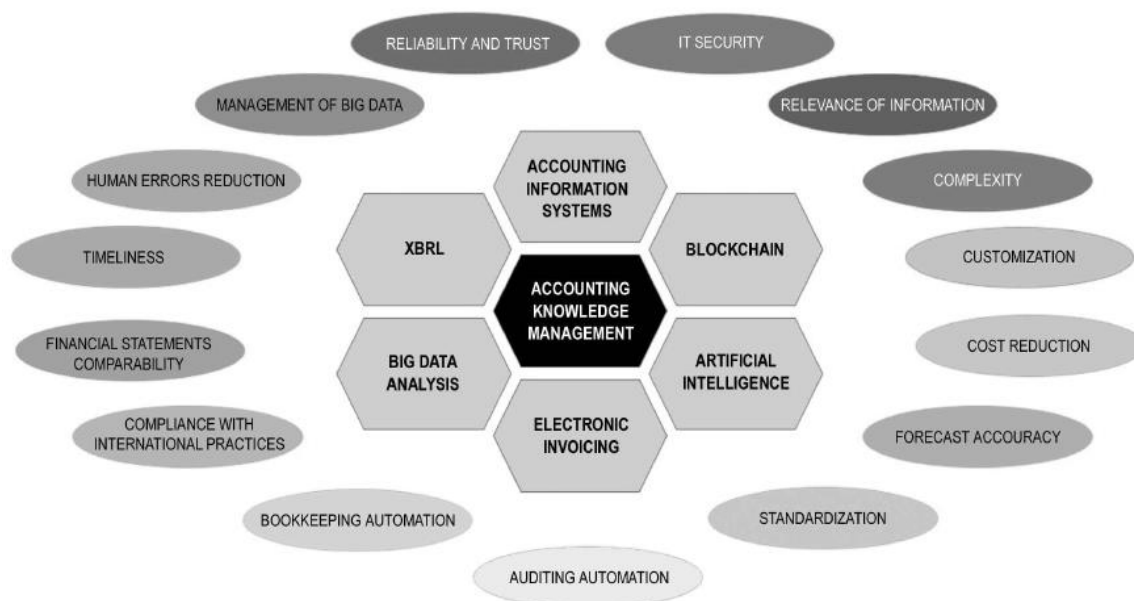


Figura 4: Futuro digitale della gestione contabile (Fonte: Digital systems and new challenges of financial management – fintech, XBRL, blockchain and cryptocurrencies Mosteanu, Faccia, 2020).

Negli ultimi due decenni, l'intelligenza artificiale è cresciuta notevolmente; il suo mercato (hardware e software) ha raggiunto \$ 9 miliardi nel 2018 e la società di ricerca IDC (International Data Corporation<sup>14</sup>) prevede che il mercato sarà di \$ 47 miliardi entro il 2020. Tutto questo è possibile attraverso la gestione della conoscenza per esplorare i *Big Data* e prendere vantaggio di computer più veloci e progressi nelle tecniche di apprendimento automatico (Mosteanu, Faccia, 2020).

Per essere efficace ed efficiente, il sistema deve soddisfare i seguenti criteri di prestazione per giustificare la sua adozione:

- Semplicità: facile da capire;
- Aggregazione: utile per aggregare grandi volumi di informazioni;
- Esplorazione: abilita l'esplorazione dei dati eseguendo il drill down<sup>15</sup> su elementi o problemi;
- Relazioni: abilitare l'identificazione di relazioni o modelli nei dati che altrimenti sarebbero difficili da ottenere con i dati testuali;
- Rilevamento: migliora le indagini e le analisi per potenziali frodi;
- Innovazione: fornire un modo innovativo di presentare informazioni (Singh, Best, 2016).

<sup>14</sup> è la prima società mondiale specializzata in ricerche di mercato, servizi di consulenza e organizzazione di eventi nei settori ICT (Information and Communications Technology) e dell'innovazione digitale.

<sup>15</sup> Andare a fondo

Le aziende che utilizzano in modo efficace ed efficiente i *Big Data* hanno il potenziale per ottenere significativi vantaggi competitivi tra cui la prevenzione dei costi, l'aumento dei profitti, il pensiero chiaro e lo sviluppo di nuovi prodotti / servizi (Dennehy, 2016). Enget, Saucedo, Wright, (2017) commenta che i *Big Data* hanno il potenziale per migliorare le previsioni di stime, preoccupazione, frode e altre variabili simili che destano preoccupazione.

Al momento, il numero di ragionieri si sta riducendo, le aziende cercano ora meno dipendenti ma più qualificati (Richards et al., 2019). I contabili devono essere in grado di utilizzare perfettamente i sistemi di informazione e devono anche essere in grado di personalizzarli. La conoscenza dell'IT è quindi ora senza dubbio essenziale. La gestione della conoscenza (O'Leary, 2018) nei dipartimenti di contabilità è sempre più orientata all'integrazione dei sistemi IT con competenze finanziarie, contabili e legali. La sfida principale è quella di creare team di persone in grado di comprendere e applicare le conoscenze trasversali, in grado di ragionare in termini di diagramma di flusso, al fine di comunicare con un singolo denominatore comune ed esprimere le reciproche esigenze di lavoro. La combinazione positiva tra IT e contabilità sta consentendo un'informatica sempre più tempestiva e affidabile, che sta portando a un'uniformità di esposizione (Mosteanu, Faccia, 2020).

### **3.3.2 Modelli di *Big Data* applicati per rilevare la frode**

La frode contabile è un problema mondiale e se non rilevata e prevenuta in modo tempestivo, può causare danni significativi alle parti interessate di imprese fraudolente (ad es. WorldCom) nonché alle parti interessate di molte imprese non fraudolente indirettamente (Gleason, Jenkin, Johnson 2008, Goldman, Peyer, Stefanescu 2012, Hung, Wong, Zhang 2015). Sfortunatamente, la frode contabile è difficile da rilevare ed anche se viene rilevata, di solito sono già stati arrecati gravi danni (Dyck, Morse, Zingales 2010). Pertanto, metodi efficienti ed efficaci per il rilevamento delle frodi contabili offrirebbero un valore significativo a contabili, revisori e investitori (Bao, Ke, Li, Yu, Zhang, 2020).

Senza strumenti adeguatamente progettati, i professionisti possono incontrare difficoltà a scoprire schemi utili per dati complessi, scoprire comportamenti fraudolenti nascosti e raccogliere prove valide da dati di volume elevato, varietà elevata e alta velocità. Pertanto, lo sviluppo di strumenti di analisi dei dati efficienti ed efficaci è un problema critico per tutti i professionisti che affiancano l'azienda. (Dai, Li, 2016).

Nel momento in cui introducessero app di controllo, ciascuna di esse eseguirebbe spesso un singolo test di controllo analitico. Tali test possono variare da una semplice query, come il rilevamento di pagamenti doppi e l'identificazione di transazioni speciali, a tecniche avanzate di analisi dei dati, come la legge di Benford (Nigrini 1999) e il clustering (Byrnes 2015; Thiprungsri, Vasarhelyi 2011). Le app di controllo di solito richiedono poche interazioni con l'utente, quindi gli utenti devono solo caricare i dati nelle app, da lì otterrà risultati senza molte operazioni complicate. Si possono persino creare app di controllo personalizzate per svolgere attività di controllo speciali. Queste tecniche richiedono conoscenze sufficienti nell'analisi dei dati ma potrebbe essere difficili, per la maggior parte soggetti e gli sviluppatori, considerare i punti di forza e gli svantaggi unici di ogni tecnica durante la progettazione di app (Dai, Li, 2016).

Gli investigatori delle frodi hanno recentemente riconosciuto l'importanza della *data visualization* per il loro rilevamento e stanno iniziando a implementarla (Deloitte, 2011; Clopton et al., 2014). La *data visualization* è particolarmente importante nelle prime fasi dell'indagine sulle frodi, in cui l'investigatore sta tentando di eseguire un'analisi dei dati efficiente ed efficace e desidera comprendere meglio le relazioni che potrebbero essere presenti in un insieme di dati. L'investigatore può utilizzare questo metodo come approccio di rilevamento proattivo, utilizzandolo per cercare modelli di dati che suggeriscono attività fraudolente (Albrecht et al., 2012) e in seguito sviluppare una teoria della frode che viene successivamente utilizzata per selezionare ulteriori procedure investigative (Wells, 2003).

In questo caso, l'investigatore sta seguendo un approccio di verifica delle ipotesi, sviluppando ipotesi preliminari sulla frode e analizzando i dati rilevanti per vedere se sembrano veri. Se la fase di analisi dei dati d'indagine per frode non supporta l'ipotesi che si sia verificata una frode, l'inchiesta termina. D'altra parte, se l'analisi dei dati produce risultati coerenti con l'ipotesi che si sia verificata una frode, l'investigatore procederà ad altre procedure investigative, come l'esame dei documenti e l'intervista a possibili testimoni (Dilla, Raschke, 2015).

Dato il potenziale della *data visualization* di aiutare gli investigatori a vedere e comprendere modelli di dati coerenti con l'attività fraudolenta, i professionisti della contabilità forense hanno recentemente raccomandato l'uso di questa tecnologia come strumento investigativo (Deloitte, 2011; Clopton et al., 2014). I sostenitori del software di *data visualization* affermano che faciliti decisioni migliori supportando il pensiero



visivo. Ad esempio, il consulente Stephen Few afferma che “*Visual analysis software allows us to not only represent data graphically, but to also interact with those visual representations to change the nature of the display, filter out what's not relevant, drill into lower levels of detail, and highlight subsets of data across multiple graphs simultaneously. This makes good use of our eyes and assists our brains, resulting in insights that cannot be matched by traditional approaches* (Few, 2007)” ovvero che Il software di analisi visiva consente non solo di rappresentare graficamente i dati, ma anche di interagire con quelle rappresentazioni visive per cambiare la natura del display, filtrare ciò che non è rilevante, passare a livelli inferiori di dettaglio ed evidenziare sottoinsiemi di dati su più grafici contemporaneamente. Questo può dar vita a intuizioni che non possono essere eguagliate dagli approcci tradizionali.

Il vantaggio del software per l'identificazione di modelli di dati che suggeriscono frodi, è che consente di cambiare rappresentazione ed esplorare i dati su un'unica piattaforma, altrimenti, l'investigatore dovrebbe utilizzare più piattaforme, vale a dire, estrarre i dati utilizzando un programma software, quindi esportarli in un programma per fogli di calcolo per l'analisi grafica. L'utilizzo di un unico modello consente allo sperimentatore di scegliere più facilmente rappresentazioni che si adattano in modo cognitivo ai diversi passaggi di questa attività, risultando in una maggiore precisione nel rilevamento di transazioni fraudolente in un determinato set di dati.

Un'indagine sulla frode inizia con una previsione di frode, o con una circostanza, che porterebbe un professionista ragionevole e prudente a credere che si sia verificata una frode (Albrecht et al., 2012, 80). Una volta che un investigatore della frode evidenzia una previsione, deve sviluppare una teoria su come si è verificata e su chi potrebbe averla commessa (Wells, 2003; ACFE, 2010). In questo caso, l'investigatore ha già ipotizzato che sia stata commessa in un reparto specifico (esempio acquisti, attraverso acquisti effettuati al di sopra dei prezzi di mercato, pagamenti a un venditore fittizio o entrambi) ma è necessario andare a fondo. La *data visualization* consente allo sperimentatore di perfezionare ulteriormente la teoria delle frodi individuando prima le anomalie analitiche che suggeriscono la frode e successivamente identificando specifiche transazioni sospette e le persone responsabili.

I professionisti raccomandano di utilizzare metodi proattivi di rilevazione delle frodi nell'ambito di un efficace programma di gestione del rischio di frode (Lanza, 2005b; Albrecht et al., 2012), in quanto è quello che identifica le aree in cui vi è un alto rischio di

transazioni fraudolente (ad es. Acquisti di forniture, spese di viaggio e di intrattenimento o acquisto di carte), e utilizza metodi di analisi dei dati computerizzati per la ricerca di anomalie.

Tali procedure potrebbero essere eseguite periodicamente da revisori interni o su base continuativa da parte di personale la cui responsabilità primaria è il rilevamento di frodi. Pertanto, il processo di analisi dei dati per indagare su sospette frodi e rilevare transazioni fraudolente è simile, in quanto l'investigatore valuta una serie di ipotesi preliminari sulla frode (Albrecht et al, 2012). La differenza principale tra i due scenari è che quando indaga su sospette frodi, l'investigatore inizia con ipotesi basate su una previsione, mentre quando esegue procedure proattive d'individuazione di frodi, l'investigatore sviluppa ipotesi basate su un'analisi del rischio di dove e quando è probabile che si sia verificata la transazione fraudolenta (Dilla, Raschke, 2015).

È importante introdurre il concetto dell'accuratezza che consiste nel trarre una conclusione corretta sulla presenza o assenza di transazioni fraudolente significative in un dato set di dati. Un investigatore che segue un sospetto di frode s'impegna in un processo iterativo, in cui sviluppa una o più teorie sulla frode (Wells, 2003; ACFE, 2010). Come già sottolineato, se i dati preliminari convalidano una teoria della frode, l'indagine continua con ulteriori prove di raccolta e infine, con interviste a testimoni e dell'autore stesso. Altrimenti, se nessuna delle teorie sulla frode appare praticabile, l'inchiesta termina. Pertanto, possono esserci due tipi di errori in un'indagine per frode:

- l'investigatore smette di raccogliere prove, anche se sono presenti transazioni fraudolente;
- l'investigatore continua a raccogliere prove in assenza di transazioni fraudolente.

I costi di questi due errori sono in genere asimmetrici, poiché la mancata individuazione di frodi significative è generalmente più costosa rispetto allo svolgimento di procedure investigative non necessarie.

In ambito di revisione il processo decisionale relativo alle frodi è leggermente diverso. Il revisore non sta lavorando con una previsione di frode; piuttosto, è tenuto a giungere a una conclusione sul fatto che il bilancio contenga errori significativi dovuti a frodi (AICPA, 2013, AU-C 240.A56). Pertanto, i due possibili tipi di errori relativi al rilevamento di frodi in un audit sono:

- il revisore non riconosce la presenza di transazioni fraudolente, non apporta modifiche appropriate nelle procedure di revisione e non rileva le frodi materiali;

- il revisore conclude erroneamente che sono presenti transazioni fraudolente ed esegue procedure di revisione non necessarie.

I costi di questi due tipi di errori sono generalmente asimmetrici poiché i compromessi tra i due tipi di errori di rilevamento delle frodi sono complessi e varieranno da un contesto all'altro.

Le decisioni corrette nel contesto dell'indagine sulle frodi sono binarie, il termine accuratezza nelle proposte di ricerca si riferisce alla percentuale di casi in cui lo sperimentatore conclude correttamente che le transazioni fraudolente sono o non sono presenti in un determinato set di dati (Dilla, Raschke, 2015).

L'introduzione di questi sistemi porta alla creazione di determinate proposizioni:

Proposta 1a. Gli investigatori avranno bisogno di meno tempo per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente quando usano gli strumenti interattivi, rispetto agli strumenti statici.

Proposta 1b. Gli investigatori trarranno conclusioni accurate sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati più spesso quando utilizzano strumenti interattivi, rispetto agli strumenti statici.

Proposta 2a. La riduzione del tempo necessario per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati realizzato da strumenti interattivi, a differenza degli strumenti di visualizzazione statica, sarà maggiore nel complesso che nei semplici scenari di rilevamento delle frodi.

Proposta 2b. L'aumento della proporzione di conclusioni accurate riguardanti la presenza o l'assenza di transazioni fraudolente in un determinato set di dati ottenuto da strumenti interattivi, rispetto agli strumenti di visualizzazione statica, sarà maggiore in complessi che in semplici scenari di rilevamento delle frodi.

Gli effetti degli strumenti interattivi di visualizzazione dei dati sulle strategie e sui giudizi di ricerca d'informazioni sulla rilevazione di frodi saranno probabilmente non solo sulla difficoltà del compito, ma anche sull'esperienza e sui livelli di conoscenza degli investigatori. Cardinaels (2008) rileva che i partecipanti meno esperti che svolgono un compito di giudizio utilizzando i dati contabili sono più accurati quando usano i grafici, mentre i partecipanti più competenti sono più precisi utilizzando le tabelle. I partecipanti più informati trascorrono più tempo nella ricerca delle informazioni con le tabelle, ma il formato di visualizzazione delle informazioni non influisce sul tempo di ricerca delle informazioni dei partecipanti meno esperti.

Pertanto, l'efficacia degli strumenti interattivi di visualizzazione dei dati nel rilevamento di transazioni fraudolente è probabilmente subordinata sia alla difficoltà del compito che all'esperienza del rilevamento di frodi degli investigatori. In un'attività di rilevazione delle frodi meno complessa, gli investigatori esperti possono concentrarsi sull'estrazione analitica e sul calcolo delle differenze tra i singoli valori. Si identificano quindi le due proposte:

Proposta 3a. In semplici scenari di rilevamento delle frodi, la riduzione del tempo necessario per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati ottenuto da strumenti interattivi, rispetto agli strumenti di visualizzazione statica sarà maggiore per i non esperti che per gli investigatori esperti.

Proposta 3b. In semplici scenari di rilevamento delle frodi, l'aumento della percentuale di conclusioni accurate relative alla presenza o all'assenza di transazioni fraudolente in un determinato set di dati ottenuto da strumenti interattivi, rispetto agli strumenti di visualizzazione statica, sarà maggiore per i non esperti che per gli investigatori esperti.

L'opposto potrebbe verificarsi per compiti di rilevazione di frodi più complessi. Gli investigatori esperti potrebbero ritenere necessario fare affidamento sulla visualizzazione delle tendenze dei dati con l'aumentare della complessità delle attività. Gli strumenti interattivi di visualizzazione dei dati supporteranno questa strategia in misura maggiore rispetto alle rappresentazioni statiche. D'altra parte, può verificarsi un effetto massimo per gli investigatori non esperti che devono affrontare un complesso compito di rilevazione delle frodi. Questo porta alle seguenti proposte:

Proposta 4a. In scenari complessi di rilevamento delle frodi, la riduzione del tempo necessario per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati realizzato da strumenti interattivi, rispetto agli strumenti di visualizzazione statica, sarà maggiore per gli esperti che per gli investigatori non esperti.

Proposizione 4b. In scenari complessi di rilevamento delle frodi, l'aumento della percentuale di conclusioni accurate relative alla presenza o assenza di transazioni fraudolente in un determinato set di dati ottenuto da strumenti interattivi, rispetto agli strumenti di visualizzazione statica sarà maggiore per gli esperti che per gli investigatori non esperti.

Proposta 5a. Gli investigatori non esperti richiederanno meno tempo per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati con strumenti di visualizzazione dei dati interattivi strutturati anziché non strutturati.

Proposta 5b. Gli investigatori non esperti trarranno conclusioni più accurate sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati più spesso quando utilizzano strumenti di visualizzazione di dati interattivi strutturati, anziché non strutturati.

Pertanto, prevediamo che le tecniche strutturate di *data visualization* influenzeranno l'efficienza e l'accuratezza delle decisioni degli investigatori di frodi solo per compiti complessi di rilevazione delle frodi.

Proposta 6a. In scenari complessi di rilevamento delle frodi, gli investigatori esperti richiederanno meno tempo per giungere a una conclusione sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati con strumenti di visualizzazione dei dati interattivi strutturati anziché non strutturati.

Proposizione 6b. In scenari complessi di rilevamento delle frodi, gli investigatori esperti trarranno conclusioni più accurate sulla presenza o l'assenza di transazioni fraudolente in un determinato set di dati più spesso quando utilizzano strumenti di visualizzazione di dati interattivi strutturati e non strutturati.

Mentre queste affermazioni sostengono un argomento plausibile sul perché il software di *data visualization* potrebbe facilitare il rilevamento di transazioni fraudolente, prove di ricerca suggeriscono che l'efficacia dei display, grafici interattivi per il processo decisionale dipende dal compito e dalle caratteristiche dell'utente (Lurie, Mason, 2007; Baker et al., 2009; Dilla et al., 2010; Yigitbasioglu, Velcu, 2012).

Anche se le tecniche di *data visualization* hanno il potenziale per essere un potente strumento di rilevamento delle frodi (Deloitte, 2011), ci sono poche ricerche che esaminano direttamente l'efficacia di queste tecniche in contesti di rilevamento delle frodi. La ricerca comportamentale in materia di contabilità si concentra sulla capacità dei decisori di utilizzare segnali testuali e numerici per l'analisi e l'individuazione del rischio di frode, e questa ricerca si concentra quasi interamente su segnalazioni finanziarie fraudolente (ad esempio, Hogan et al., 2008).

Fino ad oggi, poche ricerche hanno esaminato se e in che modo il software potrebbe consentire agli investigatori di vedere modelli nei dati che sono indicativi di attività

fraudolente. La ricerca su questo argomento è importante, dato che ci sono costi di formazione associati all'adozione del software di *data visualization* ed è importante che i professionisti sappiano in quali circostanze tale software potrebbe facilitare il rilevamento più efficiente ed efficace di transazioni fraudolente.

Inoltre la *data visualization* ha il potenziale di migliorare l'efficacia delle tecniche di *data mining* rendendo più semplice per gli auditor la comprensione e l'analisi dei dati prodotti da queste tecniche (Dilla, Raschke, 2015).

Molti affermano che la professione di revisore sarebbe l'ultima ad adottare nuove tecnologie, che i regolamenti modellano la portata, l'ampiezza e la metodologia dell'incarico. Tuttavia, gli standard non definiscono esplicitamente il tipo di approcci analitici che i revisori dovrebbero adottare per soddisfare i requisiti ma richiedono che vengano intraprese procedure analitiche in aggiunta alla raccolta delle prove nelle fasi di revisione preliminare e finale (Daroca, Holder, 1985), ma la decisione su quali tecniche analitiche usare è lasciata al giudizio del revisore (Appelbaum, Kogan, Vasarhelyi, 2018); stabiliscono inoltre che i revisori devono rispondere ai rischi di frode identificati aumentando l'estensione delle procedure di revisione da eseguire (Dilla, Raschke, 2015). Con l'emergere dei *Big Data* e l'uso crescente di analisi da parte dei clienti della revisione contabile, l'attuale professione di revisore ha sollevato nuove preoccupazioni. I clienti di *audit* utilizzano progressivamente *Big Data* più complessi e i revisori temono che, potrebbero non essere pertinenti o efficaci (Appelbaum, Kogan, Vasarhelyi, 2018), in quanto il revisore tradizionale non è addestrato per affrontare efficacemente queste complessità. Una soluzione prevede l'automazione, eliminando così i difficili punti di decisione manuali all'interno del processo, ciò consentirebbe ai professionisti di concentrarsi sull'indagine e la risoluzione dei problemi, piuttosto che essere gravati dagli aspetti tecnici (Byrnes, 2019).

Pertanto, i professionisti dell'esame delle frodi raccomandano l'uso di procedure di *data mining* per rilevare transazioni fraudolente (Dilla, Raschke, 2015).

Il punto di fusione tra *data mining* e rilevamento di frodi contabili è che il *data mining* come strumento analitico avanzato può aiutare i revisori nel processo decisionale e nel rilevare frodi ed ha il potenziale per risolvere la contraddizione tra effetto ed efficienza del rilevamento delle frodi.

Svolge un ruolo importante nel rilevamento delle frodi nella contabilità, poiché viene spesso applicato per estrarre e scoprire i modelli nascosti in una raccolta di dati molto

ampia, sui quali un revisore non può mai essere certo della legittimità e dell'intenzione dietro una transazione fraudolenta (Han, 2017).

Anche nell'esecuzione delle procedure di *data mining*, gli investigatori possono rilevare la frode con diverse modalità. La prima è eseguire una sessione di brainstorming su possibili irregolarità che potrebbero verificarsi nei processi aziendali o nelle transazioni che stanno esaminando o potrebbe essere stata loro fornita una previsione del verificarsi di una frode. Indipendentemente dal fatto che identifichino possibili attività fraudolente attraverso il brainstorming o ricevano una previsione di frode, gli investigatori delineano quindi i modi in cui presentare i dati. Per ciascun indicatore così identificato, gli investigatori progettano una procedura di *data mining* volta a identificare se ci sono singole transazioni che devono essere esaminate più da vicino.

Una tecnica sviluppata in risposta a queste problematiche è il test di immissione su giornale con supporto software (Lanza, 2006; Lanza, Gilbert, 2007; CAQ, 2008). Per questo l'analisi di Debreceeny e Gray (2014), sulle applicazioni di *data mining* per il rilevamento di frodi negli audit di rendiconto finanziario, non solo identificano le voci di giornale come fonte chiave d'informazioni, ma suggeriscono anche che i revisori considerano le informazioni di *mining* come divulgazioni XBRL, pubblicazioni di social media e documenti giustificativi per le transazioni di entrate (Dilla, Raschke, 2015).

Secondo le linee guida AICPA (2002)<sup>16</sup> e CAQ (2008)<sup>17</sup> i vantaggi di testare le registrazioni a giornale sono:

- l'attenuazione del rischio fraudolento di iscrizione a giornale;
- la capacità di testare i controlli delle registrazioni a giornale, nonché l'eventuale elusione di tali controlli;
- la capacità di testare una popolazione completa (piuttosto che test a campione);
- la raccolta di dati quantitativi più sostanziali (Enget, Saucedo, Wright, 2017).

Il test delle registrazioni a giornale è una procedura di audit chiave eseguita per affrontare il rischio di errori significativi dovuti a frodi e al controllo da parte della direzione. A seguito di AU 316, paragrafo 58<sup>18</sup> un errore significativo nei rendiconti

---

<sup>16</sup> Istituto Americano dei Dottori Commercialisti e Revisori Contabili.

<sup>17</sup> Center for Audit Quality.

<sup>18</sup> Il paragrafo 58 afferma: gli errori significativi nei rendiconti finanziari dovuti a frodi spesso implicano la manipolazione del processo di rendicontazione finanziaria mediante:

finanziari a causa di frodi comporta spesso la manipolazione del processo di rendicontazione finanziaria registrando voci di giornale inadeguate o non autorizzate (AICPA, 2002). Ad esempio, i dirigenti di *WorldCom* hanno utilizzato numerose tecniche di manipolazione delle registrazioni a giornale per aumentare gli utili, annullare le passività e riclassificare le spese come attività e alcune voci di diario sono state registrate tre settimane dopo la chiusura dei libri del trimestre, mentre altre voci per un totale di milioni di dollari sono state supportate esclusivamente da un Post-It (Scharff, 2005). A causa del volume di registrazioni a giornale, della frequenza con cui vengono registrate le registrazioni a giornale e della documentazione di supporto richiesta per le registrazioni, l'analisi dei dati può migliorare notevolmente la capacità di un revisore di affrontare e rispondere al controllo sui rischi di registrazione a giornale, compresi i rischi di frode (Enget, Saucedo, Wright, 2017).

Le voci di giornale di *mining* e altre informazioni relative al rendiconto finanziario producono risultati testuali e numerici complessi. L'estrazione di voci di giornale implica l'utilizzo di software di audit generalizzato, query di database o analisi di fogli di calcolo per identificare elementi che suggeriscono tentativi di falsificare i rendiconti finanziari in modo fraudolento (Lanza, 2006; Lanza, Gilbert, 2007; CAQ, 2008). Queste voci possono avere caratteristiche come essere (AICPA, 2013, AU-C 240.A49):

- effettuati su conti non collegati, insoliti o usati di rado,
- creati da persone che tipicamente non fanno registrazioni prima nota,
- registrati alla fine del periodo o come voci di chiusura con poca o nessuna spiegazione (Dilla, Raschke, 2015).

Gli investigatori possono applicare una regola di punteggio alle transazioni sopra identificate per distinguere ulteriormente tra falsi positivi e voci di giornale che indicano un'elevata probabilità di frode. Questo approccio, tuttavia, produce un punteggio unidimensionale e non mostra chiaramente relazioni insolite che potrebbero suggerire una frode. Per vedere meglio le relazioni insolite tra i dati delle registrazioni a giornale, Lanza (2006) suggerisce di rappresentare graficamente il numero di transazioni per ciascun conto di contabilità generale (debiti e crediti separatamente). Allo stesso modo,

---

(a) la registrazione di voci di giornale non autorizzate inadeguate durante tutto l'anno o alla fine del periodo;

(b) l'apporto di rettifiche agli importi riportati nel bilancio che non sono riflessa nelle voci di giornale ufficiali, ad esempio attraverso rettifiche consolidate, combinazioni di report e riclassificazioni.



si potrebbero rappresentare graficamente gli importi rispetto ai conti o il numero di voci approvate da ciascun individuo. I grafici che mostrano più attributi contemporaneamente sarebbero ancora più utili per questo tipo di analisi. (Dilla, Raschke, 2015).

Un'altra tecnica di *data mining* è il *clustering*, promossa nelle recenti linee guida di audit come strumento per condurre attività di valutazione del rischio di frode; in particolare, il processo completo di *clustering* e rilevamento dei valori anomali comporta diverse fasi tecniche:

- la preelaborazione dei dati;
- la costruzione del modello;
- la selezione del modello;
- il rilevamento dei valori anomali.




Figura 5. Struttura dei passaggi primari nel clustering per il rilevamento dei valori anomali. (Fonte: Automated clustering for data analytics - Byrnes, 2019).

Questi sono tutti compiti impegnativi che storicamente comportavano una notevole quantità di sforzi manuali e, sfortunatamente, ciò ha posto notevoli difficoltà che molti professionisti non erano in grado di risolvere efficacemente. Mentre un *clustering* completamente automatizzato e un programma di rilevamento anomalo porrebbero rimedio a questo problema, un'applicazione simile non è ancora emersa sul mercato. Sebbene il software sia disponibile in commercio per eseguire funzioni di *data mining*, non è però in grado di gestire le fasi principali del *clustering* e del rilevamento anomalo in modo puramente automatizzato. Ad esempio, tale software non è in grado di eseguire una serie di simulazioni con le quali vengono automaticamente costruiti e valutati una serie di modelli di *clustering*, in modo da scegliere quello che presenta la massima qualità del cluster. Inoltre, non è equipaggiato per eseguire il rilevamento dei valori anomali per i *cluster* normali. In particolare, mentre si può prevedere che un piccolo *cluster* di appartenenza potrebbe essere costituito esclusivamente da oggetti anomali, i restanti cluster normali potrebbero spesso includere sia oggetti regolari che anomali.

Per distinguerli, è necessario effettuare un rilevamento di anomalie separate. Per facilitare l'adozione del *clustering* nella pratica di audit, è necessario un software che esegua il *clustering* e il rilevamento anomalo in modo completo, il quale attualmente non è presente (Byrnes, 2019).

*Data mining* propone altri metodi di classificazione derivati dai campi della statistica e dell'intelligenza artificiale, che aiutano l'identificazione di bilanci fraudolenti attraverso tre metodi impiegati, di seguito spiegati: alberi decisionali, reti neurali e reti di credenze *bayesiane*.

Un albero decisionale (DT) è una struttura ad albero, in cui ciascun nodo rappresenta un test su un attributo e ogni ramo rappresenta un risultato del test. In questo modo, il modello predittivo tenta di dividere le osservazioni in sottogruppi reciprocamente esclusivi (Kirkos et al., 2007). La successiva divisione del campione può produrre un grande albero. Alcuni rami dell'albero potrebbero riflettere anomalie nel set di addestramento, come valori errati o valori anomali, per questo motivo, è richiesta la "potatura" degli alberi. La "potatura" degli alberi prevede la rimozione dei nodi di divisione in un modo che non influisce significativamente sulla percentuale di accuratezza del modello (Koh et al., 2004). Viene utilizzato per attività di *data mining* ma anche di apprendimento automatico, mediante algoritmi.

Le reti neurali sono costituite da neuroni nei quali ad ogni connessione è associato un valore numerico chiamato peso. Ogni neurone riceve segnali dai neuroni collegati e viene calcolato il segnale di input combinato. I neuroni sono disposti in layer (strati). Una rete a layer è composta almeno da un livello di input (primo) e di output (ultimo). Tra il livello di input e output potrebbe esistere uno o più layer nascosti.

Infine la classificazione bayesiana si basa sul teorema statistico di *Bayes*. Il teorema di *Bayes* fornisce un calcolo per la probabilità a posteriori. *Bayesian Belief Networks* (BBN) consente la rappresentazione delle dipendenze tra sottoinsiemi di attributi. Un BBN è un grafico aciclico, in cui ciascun nodo rappresenta un attributo e ogni freccia rappresenta una dipendenza probabilistica. Se una freccia viene disegnata dal nodo A al nodo B, allora A è il genitore di B e B è un discendente di A.

I tre modelli sono stati confrontati tra loro.

Tuttavia, le prestazioni di ciascuno dei tre modelli sono diverse. Il modello albero decisionale classifica correttamente il 73,6% del campione totale, il 75% dei casi di frode e il 72,5% dei casi non fraudolenti. Il modello di rete neurale riesce a classificare

correttamente l'80% del campione totale, l'82,5% dei casi di frode e il 77,5% dei casi non fraudolenti. Infine, il modello Bayesian Belief Network che ha una precisione inferiore, riesce a classificare correttamente il 91,7% dei casi di frode, l'88,9% dei casi non fraudolenti e il 90,3% del set totale.

In una valutazione comparativa delle prestazioni dei modelli possiamo concludere che la rete di credenze *bayesiana* supera gli altri due modelli e raggiunge un'accuratezza della classificazione eccezionale ma allo stesso tempo le reti neurali raggiungono prestazioni soddisfacentemente elevate, mentre le prestazioni dell'albero decisionale sono considerate piuttosto basse.

Nel valutare le prestazioni di un modello, è importante considerare i tassi di errore di tipo I e II. Un errore di tipo I viene commesso quando una società fraudolenta è classificata come non fraudolenta. Un errore di tipo II viene commesso quando una società non fraudolenta è classificata come fraudolenta. Gli errori di tipo I e di tipo II hanno costi diversi. Classificare una società fraudolenta come non fraudolenta può portare a decisioni errate, che possono causare gravi danni economici. La classificazione errata di una società non fraudolenta può causare ulteriori indagini a spese del tempo richiesto. Sebbene qualsiasi modello miri a ridurre i tassi di errore sia di tipo I che di tipo II, si presume che sia preferibile un modello quando presenta un tasso di errore di tipo I inferiore al tasso di errore di tipo II. Nel nostro confronto, tutti i modelli presentano tassi di errore di tipo I inferiori ma la rete neurale presenta la più grande differenza tra i tassi di errore di tipo I e di tipo II (Han, 2017).

I moderni sistemi ERP<sup>19</sup> (Enterprise Integrated Planning) sono in grado di registrare quotidianamente diverse migliaia di transazioni. Ciò rende difficile trovare alcuni casi di attività anomale tra transazioni legittime. Per le grandi organizzazioni che operano in un mercato digitale globale in evoluzione, ciò significa monitorare centinaia di migliaia di transazioni e quindi approfondire quelle sospette in profondità, ciò però può comportare spese considerevoli. Il rilevamento tempestivo ed efficiente di attività anomale spesso coincide con l'analisi di reti complesse (indicate come grafici nella) (Di Giacomo et al., 2010). La rappresentazione visiva di tali reti può trasmettere informazioni utili che aiutano i revisori a estrarre modelli pertinenti (Didimo, Liotta, 2006). Nel contesto del rilevamento di anomalie, nella letteratura esistente vengono

---

<sup>19</sup> Software che le organizzazioni utilizzano per gestire le attività commerciali quotidiane.

discussi diversi approcci per l'analisi visiva di attività sospette. Questi meccanismi sono di particolare rilevanza per il rilevamento di frodi nei grandi sistemi ERP.

Gli autori identificano un ampio numero di lacune di ricerca e future opportunità, compreso l'uso dei risultati precedenti sui processi utilizzati dai professionisti della contabilità per costruire progetti di visualizzazione, testarne ed esaminare l'efficacia delle tecniche di visualizzazione interattiva, compreso il rilevamento di frodi.

Schemi comuni di frode, misure preventive e sintomi (bandiere rosse) sono ben documentati (Albrecht et al., 2009; Singleton et al., 2008; Lanza, 2007, 2003; O'Gara, 2004; Greene, 2003a; Little, Best, 2003; ACFE, 2012; Wells, 2011). L'obiettivo è utilizzare questa base di conoscenza e progettare metodi di visualizzazione che sfruttino i meccanismi che possono potenzialmente fornire supporto per il rilevamento di frodi dovute dai conti nei sistemi ERP: memorizzazione di grandi volumi di dati in una forma accessibile, facilitando una ricerca efficiente dei dati e riconoscimento di schemi, consentendo il monitoraggio di un gran numero di transazioni e consentendo all'utente di modificare la ricerca in modo interattivo (Tory, Moller, 2004). Questo approccio di ricerca determina i requisiti di sistema in base alle attività che gli utenti devono eseguire. Si concentra sul rilevamento di frodi dovute dai conti nei sistemi SAP e su potenziali sintomi quali violazioni dei principi di separazione dei compiti, inversione di conti bancari e condivisione di conti bancari.

L'indicatore chiave per le frodi sono la mancanza di controlli interni o la capacità di scavalcare i controlli interni esistenti che sono attuati in modo inadeguato (ACFE, 2014).

Il sistema in fase di sviluppo intende fornire supporto al rilevamento da parte dei revisori delle frodi dovute dai conti nei sistemi ERP, considerando il rischio di sovraccarico d'informazioni tipicamente associato ai rapporti tradizionali. In particolare, è necessario il supporto visivo per il riconoscimento dei sintomi tipici di tali frodi, come condivisione dei conti bancari da parte dei fornitori, fornitori con conti bancari multipli, modifiche ai dettagli del conto bancario del fornitore e frequenze impreviste di cifre iniziali nelle transazioni contabili (Singh, Best, 2016).

L'audit intrapreso in un incarico, in cui sono disponibili *Big Data*, può risultare un insieme di tecniche identificate da un sistema a computer, che definisce le azioni che devono essere intraprese dal revisore, con l'obiettivo di ridurre il rischio. Ad esempio, le tecniche che utilizzano varie fonti di *Big Data* potrebbero essere utilizzate per arrivare a

un punteggio quantitativo del parere di audit, in contrapposizione all'attuale parere positivo/negativo.

I tipi più comuni di tecniche utilizzate nell'audit sono i modelli di aspettativa. Le norme stabiliscono che i revisori dovrebbero sviluppare le aspettative dei conti nella fase di valutazione del rischio (PCAOB AS2110.48, 2016b). Un tipico modello di aspettativa è una relazione empirica tra più numeri contabili o alcune altre importanti misure quantitative delle operazioni aziendali.

Un modello di aspettativa viene dedotto dall'archivio dei record storici. Se risulta possibile dedurre una relazione empirica stabile che si adatta bene ai documenti storici, è ragionevole aspettarsi che questa relazione duri nel prossimo futuro, supponendo che non si verifichino cambiamenti significativi nel business. Pertanto, questa relazione fornisce un modello di aspettativa per i numeri contabili e altre importanti metriche di business nel prossimo futuro.

È comune tra i revisori concentrarsi su un determinato numero contabile (ad esempio, le entrate) e rappresentare un modello di aspettativa come equazione per questo numero contabile. Quindi, per un determinato livello di confidenza, questa equazione può essere utilizzata per derivare un intervallo di predizione per il valore futuro del numero contabile. Se il valore futuro effettivo si trova all'interno dell'intervallo di previsione, questo può essere interpretato come una prova evidente che il numero di conto è rappresentato correttamente; altrimenti, se il valore futuro effettivo non rientra nel modello di previsione, il revisore dovrà condurre ulteriori indagini per determinare se esiste effettivamente un problema con questo numero contabile. Il modello di aspettativa costituisce la base dell'esame di audit nell'incarico e determina la direzione e il grado di raccolta delle prove e il controllo di audit (Appelbaum, Kogan, Vasarhelyi, 2018).

Nella sua prima e più semplice forma, i revisori hanno iniziato a utilizzare i *Big Data* quando le tecniche di *auditing* assistito da computer (CAAT) hanno consentito di testare intere popolazioni di dati, costituite da miliardi di record, anziché basandosi sul campionamento (Data, 2010). Per decenni, le società di revisione hanno fatto affidamento sull'uso di software di analisi dei dati noto come "*generalized audit software*" (o GAS) per migliorare la qualità di una verifica. IDEA e ACL, i due pacchetti GAS più comunemente utilizzati, offrono ai revisori numerosi vantaggi come elencato di seguito:

- Verifica intere popolazioni di dati anziché solo un campione;
- Analizza i dati da una varietà di fonti, inclusi file di report e formati di dati univoci da software specifici del settore;
- Aiuta nella valutazione del rischio identificando tendenze e anomalie nei dati;
- Facilita l'analisi completa delle transazioni di contabilità generale;
- Elabora grandi volumi di dati quasi istantaneamente;
- Mantiene l'integrità dei dati di origine archiviando e presentando i dati importati in un formato di sola lettura;
- Esegue procedure di audit comuni con il clic di un pulsante;
- Funziona con qualsiasi dimensione di file e un numero illimitato di record;
- Crea un registro di ogni azione eseguita dall'utente (Brown-Liburud et al., 2015; Murphy, Tysiac, 2015; Smith, 2015).

La maggior parte delle società di revisione dispone di membri del personale addestrati all'uso di GAS e molti si aspettano che anche il personale esegua analisi dei dati.

Gli obiettivi dell'apprendimento da parte del personale, di questi metodi (GAS) sono i seguenti:

- aumentare la conoscenza dell'analisi dei dati, compresa la capacità di lavorare con file di dati di grandi dimensioni e la capacità di identificare un sistema univoco della registrazione prima nota;
- comprendere la valutazione del rischio correlato alle voci di giornale e imparare a identificare le classi di voci di giornale e voci specifiche con livelli di rischio più elevati;
- dimostrare la capacità di eseguire test per voci di giornale grandi e insolite (Fay, Negangard, 2017).

Per quanto riguarda le frodi, i revisori sono generalmente responsabili del brainstorming delle frodi e considerano la probabilità che le frodi influiscano sul rischio di *audit* (incluso l'uso di GAS) come richiesto dagli standard di *audit* (AU 316, PCAOB AS2401). Questi standard indicano inoltre che CAAT deve essere utilizzato per identificare le frodi ma tuttavia, recenti sondaggi condotti da revisori esterni rilevano che il loro uso di GAS in relazione alla frode non è elevato (Bierstaker et al., 2014; Abou-El-Sood et al., 2015). Mentre i revisori hanno un mandato generale di valutazione delle frodi, ciò non sembra tradursi nel loro lavoro quotidiano e nell'uso di GAS. I risultati mostrano che i revisori considerano GAS utile solo per rilevare errori significativi,

mentre i revisori IT ritengono che GAS sia utile sia per rilevare carenze di controllo che frodi. Poiché le aziende aumentano la dipendenza dai controlli automatizzati e diminuiscono i processi e i controlli manuali, ciò mette in dubbio se i revisori si sposteranno nella direzione di espandere il loro uso di GAS o aumenteranno la loro dipendenza dagli specialisti, come i revisori IT, in quanto i revisori non ritengono GAS utile per individuare la frode. La letteratura sostiene che considerare le frodi (ovvero il brainstorming) con specialisti più diversi (ovvero IT, specialisti fiscali e delle frodi) da una qualità superiore (Brazel et al., 2010) e si sostiene inoltre che man mano che saranno in grado di utilizzare il software con più consapevolezza, estenderanno il loro uso anche ad altre aree, come nel rilevamento delle frodi (Bradford, Henderson, Baxter, Navarro, 2020).

No, Lee, Huang, Li, (2019) sviluppano un sistema chiamato multidimensional (MADS); il framework MADS affronta le problematiche della frode, identificando i valori anomali in base a criteri multidimensionali per aiutare i revisori a concentrarsi sugli elementi più problematici durante l'esecuzione di test sostanziali. Ciò sarebbe più efficace nelle aree di audit in cui la popolazione delle transazioni è ampia ma può essere ridotta con precisione alle transazioni più rischiose utilizzando filtri appropriati. Secondo l'indagine condotta dal *Financial Reporting Council* sulle sei maggiori società di revisione del Regno Unito, l'analisi dei dati di audit è attualmente ampiamente utilizzata nei test delle registrazioni di giornale e nell'analisi di contabilità generale, e vi è anche un uso limitato nell'analisi dei ricavi e nell'analisi dei processi (Financial Reporting Council 2017), aree in cui il processo MADS sarà probabilmente più utile.

Il processo MADS mira a migliorare l'efficacia e l'efficienza del processo di audit applicando tecniche di rilevamento di valori anomali multidimensionali e dando la priorità ai valori anomali identificati nella fase di selezione dei dati di audit.

Il team determina potenziali fattori di rischio. La scoperta di elementi problematici riguardanti ciascun potenziale fattore di rischio richiede spesso che il team di audit esegua un numero significativo di procedure (o test di audit), che dovrebbero essere adattate alla natura, alla tempistica e all'estensione dei test sostanziali.

Pertanto, anziché esaminare tutti i potenziali fattori di rischio, il team dovrebbe concentrarsi su fattori significativi che sono probabilmente più adatti allo scopo previsto mediante test sostanziali (vale a dire, ottenere prove probatorie sufficienti e appropriate attraverso l'esame di elementi problematici). In particolare, nel determinare i potenziali

fattori di rischio significativi, il team dovrebbe considerare il rischio di errori significativi dovuti a potenziali frodi, l'efficacia dei controlli che sono stati implementati sull'elaborazione delle transazioni e le asserzioni di audit.

Inoltre il team sviluppa una serie di filtri destinati all'esame di potenziali fattori di rischio significativi. In particolare, i filtri devono essere adeguatamente progettati per rilevare transazioni insolite/sospette ritenute problematiche. Ciò consente ai revisori di concentrarsi sugli elementi che hanno maggiori probabilità di contenere errori durante l'esecuzione delle procedure successive.

Con l'avanzamento dei *Big Data*, l'assistenza ai revisori che si occupano di set di dati di grandi dimensioni è sempre più importante. Utilizzando una tecnica di rilevazione di valori anomali multidimensionali (MADS) che definisce le priorità, il framework consente ai revisori di ottenere un elenco più mirato di valori anomali con il più alto rischio di errori (No, Lee, Huang, Li, 2019).

Bao, Ke, Li, Yu, Zhang (2020) confrontano due tipi di modelli di previsione delle frodi definiti dalla letteratura passata, con un modello nuovo. Il primo modello definito dalla letteratura è la regressione logistica, rappresentata in molti articoli (ad esempio Beneish 1997 e 1999, Summers, Sweeney 1998, Dechow et al. 2011). Tale modello utilizza in genere indici finanziari come predittori; i rapporti sono spesso identificati da esperti sulla base di teorie. Tra gli articoli, il modello di Dechow et al. (2011) è generalmente considerato il modello di previsione delle frodi più completo nella letteratura contabile.

Il secondo modello di riferimento è un modello di previsione delle frodi sviluppato da Cecchini et al. (2010) basato su un metodo di apprendimento automatico più avanzato (di seguito denominato modello Cecchini et al.). Invece di utilizzare i rapporti finanziari identificati solo da esperti umani, Cecchini et al. (2010) sviluppano un nuovo modello di previsione delle frodi basato su *Support Vector Machines* (SVM) con un kernel<sup>20</sup> finanziario che mappa i dati finanziari grezzi in un insieme più ampio di rapporti nello stesso anno e cambiamenti nei rapporti tra diversi anni. Cecchini et al. (2010) definiscono che l'SVM con un kernel finanziario, supera i tradizionali modelli di previsione delle frodi nella contabilità, tra cui il modello Dechow et al.. Il modello proposto da Bao, Ke, Li, Yu, Zhang, (2020) di previsione delle frodi differisce da entrambi questi modelli di riferimento in due modi chiave. Innanzitutto, utilizza l'apprendimento d'insieme, un paradigma di apprendimento automatico

---

<sup>20</sup> Termine per indicare il cuore, il nocciolo.



all'avanguardia, per prevedere le frodi, successivamente utilizza elementi di dati finanziari grezzi, presi direttamente dai bilanci. Poiché gli elementi di dati finanziari grezzi sono i mattoni fondamentali del sistema contabile, è interessante esplorare se possono essere utilizzati direttamente nella previsione delle frodi. Da prima, non è chiaro se i modelli di previsione delle frodi basati su dati finanziari grezzi possano superare i modelli di previsione delle frodi basati su indici finanziari identificati da esperti. Da un lato, i modelli di previsione delle frodi basati su indici finanziari potrebbero essere più potenti perché i rapporti identificati dagli esperti umani sono spesso basati su teorie che offrono previsioni precise su quando i dirigenti aziendali hanno incentivi a impegnarsi in frodi ma poiché i modelli di previsione delle frodi basati su dati finanziari grezzi non sono direttamente collegati alla teoria, potrebbero essere meno potenti. D'altro canto, le teorie esistenti sui driver della frode contabile potrebbero essere incomplete, poiché la frode contabile è, per definizione, condotta in segreto e progettata per essere difficile da individuare. Di conseguenza, la conversione di dati contabili grezzi in un numero limitato di indici finanziari basati su teorie comportamentali potenzialmente incomplete potrebbe comportare la perdita di utili informazioni predittive. Al contrario, i modelli di previsione delle frodi che fanno uso di dati finanziari grezzi potrebbero essere più potenti perché non impongono alcuna struttura ex ante ai dati grezzi, lasciando invece che "parlino da soli". Inoltre, con il rapido avanzamento dei metodi di apprendimento automatico nell'informatica, i modelli di previsione delle frodi basati su dati grezzi possono assumere forme funzionali più flessibili e complesse, di conseguenza, tali modelli di previsione delle frodi potrebbero essere in grado di estrarre informazioni più utili dai dati non elaborati.

A causa della scarsa frequenza con cui gli AAER<sup>21</sup> della SEC identificano le frodi contabili, anche il modello di previsione delle frodi più efficace (ad es. Cecchini et al. 2010) comporterebbe un gran numero di falsi positivi che superano di gran lunga il numero di veri positivi in un periodo di prova. Chiaramente, non è pratico per i regolatori o i monitor aziendali indagare su tutti i casi previsti di frode, date le limitate risorse disponibili per combattere tale frode (Ernst & Young 2010). Anche se si volesse indagare su tutte le previsioni di frode, i costi diretti e indiretti sarebbero enormi, mentre i benefici sarebbero piccoli (perché la maggior parte delle osservazioni sulla frode

---

<sup>21</sup> Pubblicazioni contabili e di revisione dei controlli della SEC.

previste sono falsi positivi). Naturalmente, gli investigatori cercano di indagare sul minor numero di osservazioni con la più alta probabilità di frode prevista.

I risultati di questo studio suggeriscono che l'apprendimento d'insieme, se usato correttamente, è più potente della regressione logistica o SVM ai fini della previsione delle frodi ma si tratta del primo studio a valutare l'utilità dell'utilizzo di dati finanziari grezzi, piuttosto che rapporti derivati da dati finanziari grezzi, ai fini della previsione delle frodi (Bao, Ke, Li, Yu, Zhang, 2020).

Le prestazioni del metodo di base utilizzando indici finanziari supportano i risultati di Kaminski et al. e Dechow et al. I quali sostengono che i numeri finanziari di un'impresa non cambiano radicalmente tra i periodi fraudolenti e gli anni veritieri circostanti. Pertanto, i rapporti finanziari del primo anno di frode non sarebbero buoni indicatori per discernere casi fraudolenti o non fraudolenti. Al contrario, Purda e Skillicorn hanno scoperto che la ricerca delle frodi utilizzando il testo può alzare bandiere rosse da anni veritieri a periodi fraudolenti. Questo spiega perché le prestazioni di classificazione usando le funzionalità dei dati dei social media sono molto migliori rispetto a quelli che utilizzano risultati usando solo rapporti finanziari (Dong, Liao, Zhang, 2018).

I dati testuali sono il tipo più comune di *Big Data* nell'*auditing*. Rispetto ad altri tipi di *Big Data* come video o audio, il testo può essere ottenuto da fonti prontamente disponibili all'interno o all'esterno dell'azienda. Tuttavia, l'applicazione del *deep learning* nell'analisi del testo nell'*auditing* è in continua evoluzione. I pionieri in questo settore come le grandi società di contabilità hanno iniziato a utilizzare il *deep learning* per sfruttare il potere dei *Big Data* testuali per approfondire ed evidenziare aree a rischio. Ad esempio, l'analisi del contenuto di post sui social media e articoli di notizie potrebbe informare i revisori dei potenziali rischi di contenzioso, rischio aziendale, rischio di controllo interno o rischio di frode. Ad esempio, i revisori possono identificare prodotti o servizi problematici analizzando le recensioni dei clienti sul prodotto o sul servizio dell'azienda (Sun, Vasarhelyi, 2018).

Al giorno d'oggi l'estrazione del testo è un'attività estremamente difficile. Sebbene l'elaborazione automatica del testo a livello semantico rimanga un compito sfuggente, è ora possibile utilizzare metodi di estrazione del testo per estrarre informazioni significative (Guan, Levitan, Goyal, 2018). L'analisi del testo (*text mining*) è diventata uno degli strumenti più popolari per misurare il contenuto informativo delle divulgazioni aziendali, in particolare i rapporti fraudolenti. I ricercatori hanno utilizzato

metodi basati sul linguaggio per analizzare le conferenze telefoniche esecutive (Larcker, Zakolyukina, 2012), i comunicati stampa sugli utili (Davis et al., 2012) e, sicuramente, i rapporti annuali (Loughran, McDonald, 2011; Li, 2008, 2010; Brown, Tucker, 2011). In contabilità, i metodi di *text mining* e *data mining* sono stati utilizzati per oltre tre decenni (Baldwin et al., 2006). In tali campi, alcuni studi incentrati sulla segnalazione fraudolenta e il rilevamento di frodi, in generale, hanno frequentemente utilizzato questi metodi (ad esempio Kochetova-Kozloski et al., 2011; Kim, Vasarhelyi, 2012; Tackett, 2013).

L'errore di questi modelli di *text mining* è costituito da due componenti:

- Errore nel rilevamento di un indice di rischio di frode elevato: si verifica quando l'indice di rischio di frode in un anno viene rilevato elevato, mentre in realtà è basso;
- Errore nel rilevamento di un indice di rischio di frode basso: si verifica quando l'indice di rischio di frode in un anno viene rilevato basso, mentre in realtà è elevato.

È possibile che una frode, avvenuta quest'anno, venga divulgata nei prossimi anni. Se il periodo di ricerca non include l'anno in cui vengono divulgati i segni di frode, il *text mining* non può rilevare la frode. Pertanto, più lungo è il periodo di studio, maggiore sarà il rilevamento delle frodi (Rahrovi Dastjerdi, Foroghi, Kiani, 2019).

Un'altra importante area è la catena di approvvigionamento. Grandi volumi di dati e l'incapacità di analizzarli consentono alle attività fraudolente di passare inosservate nei processi di gestione della catena di approvvigionamento dove avvengono l'approvvigionamento, la gestione del magazzino e la gestione delle scorte. Questa frode aumenta il costo della gestione della catena ed è necessario un meccanismo di rilevazione per ridurre il rischio di frode.

Uno strumento per la rilevazione di questo tipo di frode può essere la legge di *Benford*, la quale con l'aiuto di procedure memorizzate, con parametri e un data warehouse, può aiutare il professionista che deve rilevare la frode. La quantità di dati prodotti ogni giorno aumenta costantemente e richiede alle aziende di arrendersi o di accettare le sfide e le opportunità che questa tendenza comporta. Grandi volumi di dati e l'incapacità di analizzarli o persino elaborarli, consentono alle tendenze fraudolente di passare inosservate, anche quando vengono introdotti nuovi dispositivi di tracciamento o

scansioni automatiche, determinati a prevenire tali tendenze, ma anche ad aumentare la quantità di dati.

La società di consulenza sul rischio Kroll<sup>22</sup> indica: *“the same information technologies that help shippers manage global supply chains could make them more vulnerable to supply-chain fraud”* (Hoffman, 2008) ovvero le stesse tecnologie informatiche che aiutano gli spedizionieri a gestire le catene di approvvigionamento globali potrebbero renderla più vulnerabili alle frodi, perciò la richiesta di analisi dei dati nella prevenzione delle frodi è elevata.

Mayne (2010) sottolinea e fornisce l'esempio delle imprese che utilizzano metodi forensi per prevedere le fluttuazioni della catena di approvvigionamento, spesso guidate dalla necessità di migliorare il proprio business, seguire le regole di conformità o preoccupazioni relative alla violazione dei dati.

La legge di Benford può essere classificata come un metodo descrittivo di *data mining*, in quanto discrimina i dati, ma anche come predittivo, in quanto identifica le caratteristiche dei set di dati che possono aiutare a prevedere schemi futuri. Tödter (2009), afferma che *“Benford’s law is a potentially useful instrument to discover fraud and manipulation as the implementation and application to the datasets documented showed the general obedience to Benford’s law (first and first-two digits) overall and enables the researcher to detect anomalies, maybe only in the form of peculiarities for further analysis”*. Si conferma che la legge di Benford è uno strumento potenzialmente utile per scoprire frodi e manipolazioni poiché l'implementazione e l'applicazione ai set di dati ha mostrato l'approvazione generale alla legge di Benford in generale e consente al ricercatore di rilevare anomalie. Tuttavia, Özera e Babacanb (2013) hanno scoperto che le divulgazioni di conti fuori bilancio di una banca turca non sono conformi alla legge di Benford, ma ammettono che se un set di dati non è conforme alla legge è sufficiente essere sospettosi riguardo a tale set di dati. (Kraus, Valverde, 2014).

Khrestina, Dorofeev, Kachurina, Usubaliev, Dobrotvorskiy, (2017) sviluppano degli algoritmi per la ricerca, l'analisi e il rilevamento di attività fraudolente, in particolare:

- Schema del Rotary ovvero il regime si basa sul principio del rimborso dell'IVA (imposta sul valore aggiunto). L'esempio è il seguente:
  1. la società A, con sede nel Paese 1, acquisisce alcuni beni da un fornitore nel Paese 2, con aliquota IVA zero;

---

<sup>22</sup> società di investigazioni aziendali e consulenza sui rischi con sede a New York City

2. al momento dell'acquisizione, la merce viene fornita a un altro operatore commerciale (società B, con sede nello stesso paese) allo stesso prezzo con IVA. Tuttavia, la società A non paga l'IVA a favore dello Stato e si trasforma in un operatore commerciale fraudolenta;
  3. società B quindi vende la merce in un altro paese (spesso alla stessa società che è un fornitore originale) e chiede il rimborso dell'IVA che è stata pagata al momento dell'acquisizione della merce dalla società A.
- Il sistema di riciclaggio basato su fatture per lavori fittizi. L'amministratore delegato della società A firma diversi contratti con subappaltatori per lavori di costruzione e assemblaggio che la società A esegue autonomamente. Quindi i lavori vengono trasferiti a un subappaltatore, lungo la catena (attraverso società di breve durata). Ciascuno di loro riceverà una somma di denaro e confermerà l'esecuzione dei lavori nell'ambito dei contratti che includevano segnalazioni finte. Alla fine della catena un proprietario della società D sta cercando di farsi ritornare il denaro, ed è implicito che questo denaro sarà ricevuto dalla direzione della società A "sottobanco" (possibilmente tramite un agente di fiducia collegato qui con la C) (Jedrzejek et al., 2009; Albekov et al., 2017; Stroeve et al., 2016; Thalassinou et al., 2012; Vovchenko et al., 2017; Bogdanova et al., 2016). Lo schema di riciclaggio basato su fatture per lavori fittizi è mostrato nella Figura 6. In questo scenario i fondi vengono ritirati dalle aziende ai privati.

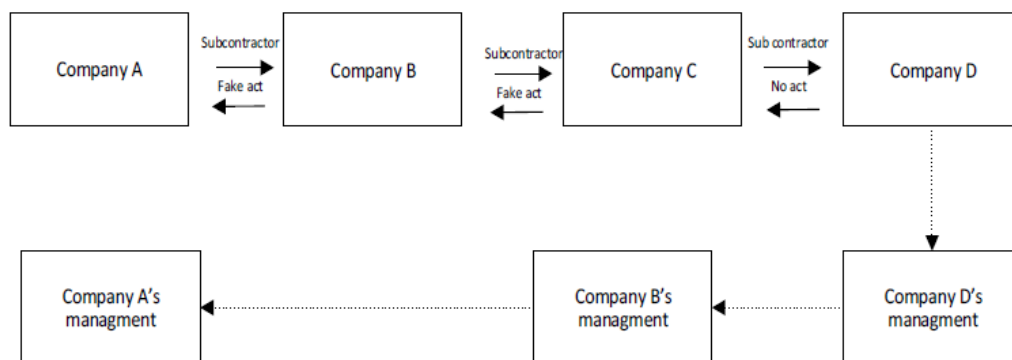


Figura 6. Il sistema di riciclaggio basato su fatture per lavori fittizi. (Fonte: Development of Algorithms for Searching, Analyzing and Detecting Fraudulent Activities in the Financial Sphere - Khrestina, Dorofeev, Kachurina, Usabaliev, Dobrotvorskiy, 2017).

- Lo schema di collocamento di fondi nel sistema finanziario attraverso il falso aziendale. Viene utilizzato lo schema di collocamento di fondi in conti bancari di

varie società. I fondi devono essere collocati regolarmente e sotto forma di ingenti somme di denaro. Questo denaro viene trasferito immediatamente sui conti delle banche straniere di proprietà di società straniere (coloro che beneficiano del regime dato). Gli indicatori di attività sospette per lo schema indicato sono i seguenti:

- 1) livello discutibile di attività commerciale reale;
- 2) trasferimenti multipli e ripetuti tra i conti;
- 3) la fonte dei fondi non può essere verificata;
- 4) assunzione di società false (o società di breve durata);
- 5) applicazione di schemi di "stratificazione".

### **3.3.3 Osservazioni finali sui modelli di *Big Data* applicati per rilevare la frode**

La frode contabile è estremamente difficile da rilevare, pertanto, un'importante area di ricerca contabile è lo sviluppo di metodi efficaci ed efficienti per rilevarla tempestivamente all'interno delle aziende, limitando in tal modo l'entità del danno ad esso correlato.

Il corretto rilevamento delle frodi dipende dalla capacità dello sperimentatore di rilevare modelli nei dati che suggeriscono transazioni fraudolente. Gli strumenti di *Big Data* hanno un potenziale sostanziale per rendere il processo di rilevazione delle transazioni fraudolente più efficiente ed efficace.

I modelli esaminati sono la conferma di ciò. Gli investigatori devono essere in grado di scegliere il modello più adatto al loro caso, avere un'adeguata formazione per utilizzarlo e affidarsi ad esso per il rilevamento della frode ma allo stesso tempo riconoscere i suoi limiti ed esprimere pareri personali, come nella rilevazione manuale.

Incorporare i *Big Data* come prove aggiuntive aiutano il rilevamento di anomalie e la previsione di frodi, migliorando la qualità dell'audit. I *Big Data* e le analisi di business ora attraversano quasi tutti gli aspetti del processo decisionale e delle strategie aziendali delle grandi aziende. L'ecosistema di dati si sta espandendo esponenzialmente e quest'ambiente presenta un insieme di dati che cambia in modo dinamico; assieme ad esso deve espandersi e variare anche la figura del professionista che utilizza questa tipologia di strumenti, in modo da essere all'altezza della sua mansione.

## Capitolo 4 Confronto tra modelli di previsione della frode

Nel seguente capitolo si andranno ad analizzare tre modelli di previsione della frode e verrà effettuato un confronto tra di essi.

I tre modelli scelti sono: regressione logistica, apprendimento automatico e apprendimento d'insieme.

Vengono confrontati questi tre modelli in quanto, essendo i *Big Data* dati grezzi, necessitano di un'attività di trasformazione chiamata *Data Mining* che li rende dati accessibili a tutti, sui quali è possibile trarre le informazioni necessarie; si tratta della più importante e conosciuta attività di trasformazione dei *Big Data*.

Un importante modello di *Data Mining* è proprio la regressione logistica, che fa parte del gruppo di apprendimento supervisionato (ovvero un processo viene valutato apprendimento supervisionato se l'obiettivo del modello è prevedere il valore di un'osservazione). Il modello di regressione logistica è un modello di regressione non lineare utilizzato quando la variabile dipendente è di tipo dicotomico e il suo obiettivo è stabilire la probabilità con cui un'osservazione può generare uno o l'altro valore della variabile dipendente.

Gli altri due modelli sono invece l'apprendimento automatico e l'apprendimento d'insieme (ovvero un modello di apprendimento automatico più avanzato). Per apprendimento automatico si intende una particolare branca dell'informatica che può essere considerata un'affine all'intelligenza artificiale.

L'apprendimento automatico e il *data mining* si sovrappongono in modo significativo, ma mentre l'apprendimento automatico si concentra sulla previsione basata su proprietà note, apprese dai dati, il *data mining* si concentra sulla scoperta di proprietà prima sconosciute nei dati. Il *data mining* sfrutta i metodi dell'apprendimento automatico, ma con obiettivi differenti; d'altro canto, l'apprendimento automatico utilizza i metodi di *data mining* come metodi di apprendimento non supervisionato. Il fraintendimento tra i due fenomeni nasce dall'assunzione di base del loro lavoro: nell'apprendimento automatico, le prestazioni sono generalmente valutate in base all'abilità di riprodurre conoscenze già acquisita, mentre nei *data mining* il compito chiave è la scoperta di conoscenza che prima non si aveva.

Essendo questi modelli correlati tra di loro e allo stesso tempo molto utilizzati nella previsione della frode si è voluto approfondire il confronto tra di essi e verificare quale tra i tre risulta essere il più efficace ed efficiente.

In questo studio si utilizzano dati contabili fuori dal campione ovvero vengono impiegati i dati di bilancio, facilmente disponibili, provenienti da società statunitensi quotate in borsa. A seguito della bibliografia già testata da Cecchini, Aytug, Koehler e Pathak (2010) e Dechow, Ge, Larson e Sloan (2011), si utilizzano gli errori contabili rilevanti, divulgati dall' "Accounting and Auditing Enforcement Releases" (AAER) della SEC come campione di frode contabile. È stato deciso di utilizzare solo dati finanziari, nonostante siano utili anche i dati non finanziari per prevedere la frode, principalmente per due motivi. In primo luogo, i modelli di previsione delle frodi basati su dati finanziari disponibili al pubblico, possono essere applicati a qualsiasi impresa quotata in borsa a basso costo. In secondo luogo, la maggior parte dei modelli di previsione delle frodi nella letteratura contabile esistente si basano su dati finanziari disponibili al pubblico, per tanto sarà possibile confrontare più facilmente e attendibilmente i modelli esposti.

Per effettuare il confronto si utilizzano due tipi di modelli di previsione della frode dalla letteratura esistente. Il primo è la regressione logistica, comunemente usata nella letteratura contabile (M. Dechow W. Ge, C. R. Larson, R. G. Sloan, 2011). Tale modello utilizza in genere indici finanziari, i quali rapporti sono spesso identificati da esperti umani sulla base di teorie; generalmente è considerato il modello di previsione delle frodi più completo nella letteratura contabile. Di conseguenza, si adotta un modello di regressione logistica come primo modello di riferimento che verrà denominato modello Dechow et al. (2011).

Il secondo modello di riferimento è un modello di previsione delle frodi sviluppato da Cecchini, Aytug, Koehler, Pathak (2010) basato su un metodo di apprendimento automatico, di seguito denominato modello Cecchini et al. (2010). Invece di utilizzare i rapporti finanziari identificati solo da esperti umani, Cecchini et al. (2010) sviluppano un nuovo modello di previsione delle frodi basato su *Support Vector Machines* (SVM) con un kernel finanziario che mappa i dati finanziari grezzi in un insieme più ampio di rapporti basati su dati dello stesso anno o su anni diversi. Cecchini et al. (2010) scoprirono che l'SVM con un kernel finanziario supera i tradizionali modelli di previsione delle frodi nella contabilità, tra cui Dechow et al..

Il modello di previsione delle frodi proposto differisce da entrambi i modelli di riferimento in due modi. Innanzitutto, si utilizza l'apprendimento d'insieme, un paradigma di apprendimento automatico all'avanguardia, per prevedere le frodi. La maggior parte delle precedenti ricerche sulla previsione delle frodi in contabilità



utilizzano la regressione logistica ma non esiste un modello universalmente migliore in tutte le impostazioni dei dati; tuttavia risulta possibile testare se il metodo di apprendimento d'insieme possa superare o no i tradizionali metodi di previsione delle frodi.

In secondo luogo, il modello proposto utilizza, come predittori di frodi, elementi di dati finanziari grezzi presi direttamente dai bilanci. Poiché gli elementi di dati finanziari grezzi sono dati fondamentali del sistema contabile, è interessante esplorare se possono essere utilizzati direttamente nella previsione delle frodi. Da un lato, i modelli di previsione delle frodi basati su indici finanziari potrebbero essere più potenti perché i rapporti identificati dagli esperti umani sono spesso basati su teorie che offrono previsioni precise su quanto i dirigenti aziendali hanno incentivi a impegnarsi in frodi e poiché i modelli di previsione delle frodi basati su dati finanziari grezzi non sono direttamente collegati alla teoria, potrebbero essere meno potenti. D'altro canto, le teorie esistenti potrebbero essere incomplete, in quanto la frode contabile è, per definizione, condotta in segreto e progettata per essere difficile da individuare. Di conseguenza, la conversione di dati contabili grezzi in un numero limitato di indici finanziari basati su teorie potenzialmente incomplete potrebbe comportare la perdita di utili informazioni predittive.

Al contrario, i modelli di previsione delle frodi che fanno uso di dati finanziari grezzi potrebbero essere più potenti perché non impongono alcuna struttura ex ante ai dati grezzi. Inoltre, con il rapido avanzamento dei metodi di apprendimento automatico nell'informatica, i modelli di previsione delle frodi basati su dati grezzi possono assumere forme funzionali più flessibili e complesse. Di conseguenza, tali modelli di previsione delle frodi potrebbero essere in grado di estrarre informazioni più utili dai dati non elaborati.

Dopo questa breve introduzione e analisi degli aspetti positivi e negativi si ritiene importante verificare se il modello di apprendimento d'insieme basato su dati non elaborati possa superare i due modelli di riferimento.

## **4.1 Modelli utilizzati per il confronto**

### **4.1.1 Introduzione al modello Dechow et al**

Il primo modello di riferimento è chiamato Dechow et al (2011) ed è basato sulla regressione logistica.

Si può considerare la regressione logistica come un metodo di classificazione rientrante nella famiglia degli algoritmi di apprendimento supervisionato dei *data mining*.

Avvalendosi di metodi statistici, la regressione logistica permette di generare un risultato che, di fatto, rappresenta la probabilità che, un dato valore di ingresso appartenga a una determinata classe.

Nei problemi di regressione logistica, la probabilità che l'output appartenga ad una classe sarà  $P$ , mentre che appartenga all'altra classe sarà  $1-P$  (dove  $P$  è un numero compreso tra 0 e 1 perché esprime una probabilità).

Tale modello (Dechow et al 2011) utilizza in genere indici finanziari come predittori, i quali rapporti sono spesso identificati da esperti umani sulla base di teorie. È generalmente considerato il modello di previsione delle frodi più completo nella letteratura contabile, di conseguenza, viene adottato come modello di riferimento per il confronto.

#### **4.1.2 Introduzione al modello Cecchini et al**

Il secondo modello di riferimento è Cecchini et al (2010) basato su un metodo di apprendimento automatico convenzionale. Invece di utilizzare i rapporti finanziari identificati solo da esperti umani, Cecchini et al. (2010) sviluppano un nuovo modello di previsione delle frodi basato su *Support Vector Machines* (SVM) con un kernel finanziario che mappa i dati finanziari grezzi in un insieme più ampio di rapporti basati su dati dello stesso anno o su anni diversi. Per i casi in cui i concetti non sono lineari, gli attributi possono essere facilmente mappati a caratteristiche lineari usando un kernel.

Un kernel è una mappatura implicita di un attributo che si trova nello spazio  $X$  degli elementi di input, su uno spazio delle caratteristiche (solitamente di dimensioni superiori). Il kernel spesso migliora la potenza di calcolo della macchina di apprendimento consentendo implicitamente combinazioni degli attributi di input, creando quindi una superficie decisionale non lineare. Fornisce un meccanismo che aiuta a svelare spazi non separabili linearmente, da quelli che sono potenzialmente separabili linearmente.

Cecchini et al. (2010) scoprono che l'SVM con un kernel finanziario, supera i tradizionali modelli di previsione delle frodi nella contabilità, tra cui Dechow et al., per questo viene preso come secondo modello di riferimento.

### 4.1.3 Introduzione al modello apprendimento d'insieme

L'apprendimento d'insieme, un paradigma dell'apprendimento automatico, ha recentemente ottenuto un notevole successo in molte applicazioni. A differenza dei metodi di apprendimento automatico convenzionali (ad es. Metodi SVM, Cecchini et al.), che di solito generano un singolo stimatore, i metodi di apprendimento d'insieme combinano le previsioni di un insieme di stimatori di base (ad es. Alberi decisionali) per migliorare la capacità di diffusione. Tuttavia, a causa della possibilità di un problema di squilibrio di classe, i metodi di apprendimento d'insieme di solito devono essere combinati con una tecnica di campionamento che bilanci la distribuzione di classe dei dati di addestramento, aggiungendo esempi alla classe di minoranza (sovracampionamento) o rimuovendo esempi dalla classe di maggioranza (sottocampionamento) (Liu, Zhou 2013). In questo studio, si utilizza una variante dell'apprendimento d'insieme chiamata *RUSBoost* (Seiffert, Khoshgoftaar, Van Hulse, Napolitano 2010) che cerca di sfruttare sia l'efficiente tecnica di sottocampionamento sia l'attuale algoritmo più influente, *AdaBoost*<sup>23</sup> (Freund, Schapire 1997). Si utilizza *RUSBoost* in quanto mostra le migliori prestazioni ed è anche più efficiente dal punto di vista computazionale grazie alla sua semplicità (Seiffert et al. 2010).

L'algoritmo *AdaBoost* è uno dei più importanti metodi di apprendimento d'insieme a causa delle sue solide basi teoriche, di forte potere predittivo e semplicità (Wu et al. 2008). La sua idea di base è quella di addestrare una sequenza di classificatori deboli (cioè modelli che sono solo leggermente migliori delle ipotesi casuali, ad esempio piccoli alberi decisionali) su campioni ripetutamente pesanti. In particolare, in ciascuna ripetizione, i pesi delle osservazioni erroneamente classificate verranno aumentati, mentre i pesi delle osservazioni correttamente classificate verranno ridotti. In questo modo, i classificatori deboli in ogni ripetizione saranno costretti a concentrarsi sulle osservazioni considerate difficili da prevedere nelle ripetizioni precedenti.

Infine, un classificatore forte può essere prodotto prendendo la media ponderata di tutti i classificatori deboli, dove il peso è il tasso di errore di classificazione di un classificatore debole nel campione di addestramento; i classificatori deboli con tassi di errore di classificazione inferiori riceveranno pesi maggiori.

---

<sup>23</sup> abbreviazione di *Adaptive Boosting*, è un meta-algoritmo di apprendimento automatico formulato da Yoav Freund e Robert Schapire, che hanno vinto nel 2003 il Premio Gödel per il loro lavoro. Può essere utilizzato insieme a molti altri tipi di algoritmi di apprendimento per migliorare le prestazioni.

RUSBoost è una variante di AdaBoost che utilizza Random Under Sampling<sup>24</sup> (RUS) per affrontare il problema dell'apprendimento degli squilibri di classe (Seiffert et al. 2010). Funziona più o meno allo stesso modo di AdaBoost, tranne per il fatto che la RUS viene eseguita in ogni ripetizione per ovviare allo squilibrio delle imprese fraudolente e non fraudolente. In particolare, durante l'addestramento del classificatore debole in ciascuna iterazione, l'algoritmo RUS utilizza l'intero campione di imprese fraudolente nel periodo di addestramento e un sotto campione generato casualmente di imprese non fraudolente nello stesso periodo. Le stime di RUSBoost richiedono la selezione del rapporto tra il numero di osservazioni di classe di maggioranza sotto campionate (vale a dire, non frodi) e il numero di osservazioni di classe di minoranza (cioè di frode). In quest'analisi, si costruisce il modello RUSBoost impostando questo rapporto su 1: 1, cioè, campioniamo lo stesso numero di osservazioni fraudolente e osservazioni non fraudolente.

## **4.2 Metriche di valutazione delle prestazioni**

Vengono utilizzate due metriche di valutazione delle prestazioni per confrontare i modelli considerati.

Il primo metodo è l'AUC, il secondo metodo è l'NDCG@ k. Di seguito viene effettuata una breve introduzione generale.

### **4.2.1 Metrica AUC**

Innanzitutto, utilizziamo l'area sotto la curva *Receiver Operating Characteristics* (ROC) chiamata *Area Under the ROC Curve* (AUC), come metrica di valutazione delle prestazioni.

L'AUC è equivalente alla probabilità che un'osservazione di frode scelta casualmente venga classificata più in alto da un classificatore, rispetto a un'osservazione di non frode scelta allo stesso modo. L'AUC per ipotesi casuali è 0,50, pertanto, qualsiasi modello ragionevole di previsione delle frodi deve avere un AUC superiore a 0,50.

Poiché il compito di previsione delle frodi può essere definito come un problema di classificazione binaria (frode vs non frode), si possono misurare le prestazioni di previsione della frode utilizzando le metriche di valutazione per i problemi di classificazione. Una metrica delle prestazioni della classificazione standard è l'accuratezza, che è definita come:

---

<sup>24</sup> Sotto campionamento casuale

$$\frac{TP + TN}{TP + FN + FP + TN}$$

Dove:

- TP (vero positivo) è il numero di anni fraudolenti che sono correttamente classificati come frode;
- FN (falso negativo) è il numero di anni di attività fraudolenta classificati erroneamente come non fraudolenti;
- TN (vero negativo) è il numero di anni di attività non fraudolenti correttamente classificati come non fraudolenti;
- FP (falso positivo) è il numero di anni di attività non fraudolenti che sono classificati erroneamente come frode.

Questa metrica delle prestazioni di classificazione standard non sarebbe appropriata nel nostro scenario a causa della natura squilibrata dei dati relativi alle frodi rispetto a quelli non fraudolenti (la percentuale di frode nel campione è inferiore all'1% ogni anno). Tuttavia, tali modelli di previsione delle frodi apparentemente ad alte prestazioni sono di scarso valore nello scenario in considerazione perché l'obiettivo principale è rilevare con precisione il maggior numero possibile di anni aziendali fraudolenti senza classificare erroneamente troppi anni aziendali non fraudolenti. Cioè, ci si sofferma sia sul tasso vero negativo cioè la specificità che sul tasso vero positivo cioè, la sensibilità.

Per valutare correttamente le prestazioni di un modello di previsione delle frodi, si potrebbe usare la precisione bilanciata "*balanced accuracy*" (BAC) come metrica di valutazione delle prestazioni alternativa (He, Ma 2013). Il BAC è definito come la media dell'accuratezza della previsione della frode all'interno di osservazioni fraudolente e dell'accuratezza della previsione non fraudolenta nelle osservazioni non fraudolente. In particolare:

$$BAC = \frac{1}{2} \times (\text{sensibilità} + \text{specificità})$$

$$\text{Dove sensibilità} = \frac{TP}{TP+FN} \text{ e specificità} = \frac{TN}{TN+FP}$$

Esistono però due importanti limiti di BAC come metrica di valutazione delle prestazioni (Larcker, Zakolyukina 2012). In primo luogo, il BAC è costruito sulla base di una soglia di probabilità di frode prevista di un determinato classificatore e la soglia viene solitamente determinata automaticamente dal classificatore per massimizzare il BAC. In altre parole, impostando una soglia di classificatore diversa, si otterrebbe un valore BAC

diverso. In assenza di alcuna conoscenza dei costi di errata classificazione dei falsi positivi rispetto ai costi di errata classificazione dei falsi negativi, non è possibile determinare la soglia di probabilità di frode ottimale ai fini della classificazione delle frodi e delle non frodi. In secondo luogo, misure come la sensibilità sono molto sensibili alla frequenza relativa delle istanze positive e negative nel campione.

Per evitare questi due limiti, si utilizza l'area sotto la curva *Receiver Operating Characteristics* (ROC) come metrica di valutazione delle prestazioni fuori campione. Una curva ROC è una rappresentazione bidimensionale delle prestazioni di un classificatore che combina il tasso positivo reale cioè la sensibilità e il tasso falso positivo ovvero la specificità in un grafico (Fawcett 2006). Il BAC sopra definito rappresenta solo un punto nella curva ROC.

È possibile ridurre le prestazioni di un modello di previsione delle frodi a un singolo scalare calcolando l'area sotto la curva ROC (AUC). Poiché l'AUC è una porzione dell'area del quadrato dell'unità, il suo valore sarà sempre compreso tra 0 e 1. Un'ipotesi casuale produce la linea diagonale tra (0, 0) e (1, 1), che ha un'area di 0,5, nessun classificatore realistico dovrebbe avere un AUC inferiore a 0,5.

#### **4.2.2 Metrica NDCG@ K**

In secondo luogo, introduciamo una metrica di valutazione delle prestazioni alternativa comunemente utilizzata per i problemi di classificazione, denominata "*Normalized Discounted Cumulative Gain*" nella posizione k (NDCG@ k).

Di conseguenza, si valutano anche le prestazioni fuori campione dei diversi modelli di previsione delle frodi utilizzando NDCG@ k. Intuitivamente, NDCG@ k valuta la capacità di un modello di previsione della frode di identificare la frode effettiva raccogliendo le prime k osservazioni in un anno di test che hanno la più alta probabilità prevista di frode. Nello studio proposto, scegliamo un k che equivale al primo 1% delle osservazioni. Selezioniamo un limite dell'1% perché in genere meno dell'1% delle imprese in un anno sono fraudolenti secondo gli AAER della SEC. I valori di NDCG@ k sono limitati tra 0 e 1.0, con il valore che cresce e più rappresenta le migliori prestazioni del modello.

Formalmente, il Guadagno cumulativo scontato nella posizione k (DCG @ k) è definito come segue:

$$DCG@ k = \frac{\sum_{i=1}^k (2^{rel_i - 1})}{\log_2(i+1)},$$

dove  $rel_i$  (rilevanza graduata del risultato nella posizione  $i$ ) è uguale a 1 se l' $i$ -esima osservazione nella classifica è una vera frode, altrimenti è 0.

Il valore  $k$  rappresenta il numero  $k$  di anni di attività in un periodo di prova, che hanno la più alta probabilità di frode prevista. Nelle analisi empiriche, si seleziona  $k$  in modo che il numero di anni di attività nella classifica, rappresenti l'1% di tutti gli anni di attività in un anno di prova. Selezioniamo un limite dell'1% perché la frequenza media delle frodi contabili punite dagli AAER della SEC è in genere inferiore all'1% di tutte le imprese in un anno.

DCG@  $k$  si basa su due ipotesi chiave:

- un'osservazione di frode reale è classificata più in alto (per esempio  $2^{rel_i} - 1 = 1$ ) di un'osservazione non fraudolenta ( $2^{rel_i} - 1 = 0$ );
- un'osservazione di frode vera è valutata più in alto tanto più è classificata in alto nella classifica. Cioè, un'osservazione di livello superiore (cioè con un  $i$  più piccola) sarà ponderata in modo più elevato dallo sconto di posizione, cioè dal denominatore  $\log_2(i + 1)$ .

NDCG@  $k$  è DCG@  $k$  normalizzato dal DCG@  $k$  ideale, ovvero:

$$NDCG@ k = \frac{DCG@ k}{ideale DCG @ k}$$

dove il DCG@  $k$  ideale è il valore DCG@  $k$  quando tutte le vere prove di frode sono classificate in cima alla classifica. Pertanto, i valori di NDCG@  $k$  sono limitati tra 0 e 1 e un valore più alto rappresenta le migliori prestazioni di classificazione di un modello.

Per illustrare in modo più intuitivo i vantaggi della seconda metrica delle prestazioni, NDCG@  $k$ , si riportano anche le seguenti due metriche delle prestazioni utilizzando solo l'1% delle aziende con le più alte probabilità di frode previste in un anno di prova:

- *sensibilità* =  $\frac{TP}{TP+FN}$ , dove TP è il numero di imprese fraudolente contenute nel primo 1% delle imprese con le più alte probabilità di frode previste in un anno di prova e FN è il numero di aziende fraudolente classificate erroneamente come aziende non fraudolente nell'ultimo 99% delle osservazioni in un anno di prova. La somma di TP e FN è il numero totale di imprese fraudolente in un anno di prova.
- *Precisione* =  $\frac{TN}{TN+FP}$  dove TN è definito sopra e FP è il numero di aziende non fraudolente classificate erroneamente come aziende fraudolente nell'1% delle aziende con le più alte probabilità di frode previste in un anno di prova. La

somma di TP e FP è il numero totale di aziende nell'1%, delle aziende con le più alte probabilità di frode previste in un dato anno di prova.

Rispetto alla prima metrica di valutazione delle prestazioni AUC, NDCG@ k evita i significativi costi diretti e indiretti dell'indagine su un gran numero di casi di frode prevista, la maggior parte dei quali è probabile che siano falsi positivi a causa del grave squilibrio dei dati. Poiché la frequenza media delle frodi contabili punite dagli AAER della SEC è inferiore all'1%, anche il modello di previsione delle frodi più efficace come Cecchini et al. (2010) identificherà un gran numero di falsi positivi. Ad esempio, la tabella 7 di Cecchini et al. (2010) riporta che lo SVM con un kernel finanziario classifica correttamente l'80% delle osservazioni di frode e il 90,6% delle osservazioni non fraudolente nel periodo di prova fuori campione, nonostante sia ritenuto il migliore tra i modelli concorrenti.

<b>Author (s)</b>	<b>Method</b>	<b>Final sample size (after excluding firms with missing values)</b>	<b>Percentage correct</b>	<b>AUC</b>
Beneish (1999)	Probit	149 Fraud	54.2 Fraud	0.492
		3.389 Non fraud	45.5 Non fraud	
Green and Chol (1997)	Neural network	192 Fraud	100.00 Fraud	0.472
		3.173 Non fraud	7.1 Non fraud	
Dechon et al. (2009)	Logistic regression	57 Fraud	70 Fraud	0.762
		1.244 Non fraud	84.9 Non fraud	
Cecchini et al.	SVM-FK	132 Fraud	80.0 Fraud	0.878
		3.187 Non fraud	90.6 Non fraud	

Tabella 7 Cecchini et al. Risultati ottenuti dallo studio comparativo di Cecchini et al (2010) utilizzando lo stesso set di dati (Fonte: Detecting Management Fraud in Public Companies- Cecchini, Aytug, Koehler, Pathak, 2010).



Tuttavia, applicando il modello Cecchini et al. al periodo di prova 2003-2008 comporterebbe troppi falsi positivi. In particolare, le frodi si sono verificate solo in 237 delle 30.883 attività analizzate da Cecchini et al. durante il periodo di prova 2003-2008. Il metodo di Cecchini et al., tuttavia, etichetterebbe erroneamente 2.881  $((1-90,6\%) * (30.883 - 237))$  osservazioni non fraudolente come frode, una grave sovrastima del numero di casi effettivi di frode nel periodo di prova. Chiaramente, non è pratico indagare su tutti i casi previsti di frode. Anche se si volesse indagare su tutte le osservazioni di frode previste, i costi diretti e indiretti per farlo sarebbero troppo elevati. Allo stesso tempo, i benefici sarebbero limitati, poiché la maggior parte delle osservazioni fraudolente previste sono falsi positivi.

NDCG @ k evita questo problema limitando l'indagine a non più di un dato numero k di anni di attività con la più alta probabilità di frode prevista nel periodo di prova.

### **4.3. Il campione**

#### **4.3.1. Periodo del campione**

Il campione selezionato copre tutte le aziende statunitensi quotate nel periodo dal 1991 al 2008. Il campione inizia nel 1991 perché in quell'anno avviene un cambiamento significativo nel comportamento fraudolento delle aziende statunitensi e la natura del comportamento della SEC. Lo scopo del programma di applicazione della SEC si è spostato dal rimedio al punitivo (Atkins, Bondi 2008). Prima del 1990, lo scopo statutario della SEC era di fornire un aiuto agli investitori danneggiati, per rimediare e di scoraggiare violazioni future; dalla metà alla fine degli anni '80, il Congresso approvò una serie di leggi che ampliavano i poteri della SEC e fornivano ad essa un nuovo compito punitivo. A seguito di queste leggi, la SEC ha acquisito il potere di cercare o imporre azioni più punitive, come:

- la capacità di perseguire sanzioni pecuniarie civili contro persone ed entità che potrebbero aver violato le leggi federali sui titoli;
- l'autorità di vietare ai direttori e agli ufficiali di società pubbliche di prestare servizio in tale veste se hanno violato le disposizioni federali antifrode;
- l'autorità di emettere ordini amministrativi di cessazione e di sequestro, ordini restrittivi temporanei e ordini di divulgazione di profitti illeciti ai trasgressori delle leggi federali sui titoli.

Inoltre, l'uso di *stock options*<sup>25</sup> come forma di compenso esecutivo è aumentato in modo drammatico durante gli anni '90 (Murphy 1999, Erickson, Hanlon, Maydew 2006). Di conseguenza, si osservano citazioni più frequenti di *insider trading*<sup>26</sup> come possibile motivo di frode contabile negli AAER pubblicati negli anni '90 rispetto agli anni '80 (Beasley, Carcello, Hermanson 1999 e Beasley, Carcello, Hermanson, Neal 2010).

Infine, un'analisi dei casi di frode contabile inclusi negli AAER negli anni '80 e '90 rivela sottili cambiamenti, nel tempo e nella natura della frode (Beasley et al. 1999 e 2010). In entrambi i periodi, le due tecniche più comuni utilizzate per fraintendere in modo fraudolento le informazioni di bilancio hanno comportato una sopravvalutazione delle entrate e delle attività. Tuttavia, gli errori nella sottovalutazione delle spese/passività sono diventati una tecnica di frode utilizzata più frequentemente negli anni '90 (un aumento dal 18% dei casi al 31% dei casi).

Il campione si conclude nel 2008 in quanto si è verificato un notevole cambiamento nell'applicazione delle frodi contabili da parte delle autorità di regolamentazione, coincidente approssimativamente con la crisi finanziaria del 2008. Il cambiamento è stato riassunto nei seguenti punti. In primo luogo, l'FBI, che aveva assegnato più di mille agenti alle indagini sulle frodi prima del 2001, dopo l'attacco terroristico dell'11 settembre ha spostato molti di questi agenti sul lavoro antiterrorismo. In secondo luogo, per deviare le critiche dalla sua incapacità di rilevare la frode Madoff<sup>27</sup>, che è stata scoperta nel 2008, la SEC ha spostato la sua attenzione dalle indagini sulla frode contabile ad altri schemi. In terzo luogo, il Dipartimento di giustizia ha preso una

---

<sup>25</sup> strumento finanziario che consente al titolare dell'opzione il diritto di acquistare o vendere azioni di un determinato titolo a un prezzo specificato per un determinato periodo di tempo.

<sup>26</sup> compravendita di titoli di una determinata società da parte di soggetti che, per la loro posizione all'interno della stessa o per la loro attività professionale, sono venuti in possesso di informazioni riservate non di pubblico dominio

<sup>27</sup> Si è trattato della più grande frode di tutti i tempi di circa 65 miliardi di dollari. Ad organizzarla è stato Bernard Madoff e a porvi fine è stato un gruppo di agenti federali che lo ha arrestato l'11 dicembre 2008 con l'accusa di truffa. Il meccanismo innescato era il seguente: i soldi versati da chi entrava per ultimo nel suo prestigioso fondo d'investimento, che aveva attratto anche ebrei a riposo ai quali garantiva un rendimento annuale fisso del 10%, servivano per liquidare i primi che chiedevano di uscire. Il meccanismo costruito da Madoff, sulla base di bilanci falsi, è crollato a causa della recente crisi finanziaria che ha spinto un numero inaspettato di clienti a richiedere indietro il proprio denaro investito. A fronte di tali richieste Madoff si è trovato improvvisamente a dover liquidare posizioni per sette miliardi di dollari ma non aveva i soldi.

decisione nel 2009, di diffondere le indagini sui casi di frode tra numerosi Uffici del Procuratore degli Stati Uniti, molti dei quali avevano poca o nessuna esperienza precedente nell'investigare e perseguire complicate frodi.

Tutti i modelli di previsione delle frodi richiedono un periodo di formazione e un periodo di prova. Per garantire l'affidabilità della formazione dei modelli, si richiede che il periodo di formazione superi i 10 anni. Inoltre, è necessario un intervallo di 24 mesi tra l'annuncio dei risultati finanziari dell'ultimo anno di formazione e l'annuncio dei risultati di un anno di prova. Dyck et al. (2010) rilevano che occorrono circa 24 mesi, in media, per la divulgazione iniziale della frode, pertanto, si utilizzano gli ultimi sei anni del nostro campione 2003-2008 come periodo di prova. Ad esempio, il periodo di formazione è 1991-2001 per l'anno di prova 2003 e 1991-2003 per l'anno di prova 2005.

#### **4.3.2. Il campione**

L'esempio di frode contabile proviene dai documenti contabili e di revisione della SEC (AAER) forniti dall'Università della *California-Berkeley*, dal database *Center for Financial Reporting and Management (CFRM)*. E' stato scelto il database CFRM per due motivi chiave. In primo luogo, la domanda di ricerca richiede l'identificazione accurata di tutti i casi di frode contabile e gli utilizzatori indicano che il database CFRM è il migliore per questo scopo. Le loro scoperte suggeriscono che nessun singolo database domina e la scelta di quale database utilizzare dipende dalla specifica domanda di ricerca.

In secondo luogo, si desidera confrontare le prestazioni dei modelli proposti con le prestazioni dei due modelli di riferimento di Dechow et al. (2011) e Cecchini et al. (2010) dato che questi modelli di benchmark fanno uso dei dati AAER, è normale utilizzare la stessa fonte di dati. Tuttavia, si riconosce che il database CFRM è soggetto al proprio potenziale bias (distorsione) di selezione, una limitazione da tenere in considerazione nell'interpretazione dei risultati.

La versione del database CFRM ottenuta a marzo 2017, copre il periodo dal 17 maggio 1982 al 30 settembre 2016. Poiché il CFRM non ha aggiornato il suo database per il periodo anteriore al 1982 e posteriore al 2016, sono stati raccolti manualmente ulteriori osservazioni di frode dal sito Web della SEC per il periodo fino al 31 dicembre 2018. La tabella 8 mostra la distribuzione delle frodi nel campione per anno nel corso degli anni fiscali 1979-2014.

<b>Anno</b>	<b>N° totale di</b>	<b>N° di imprese</b>	<b>Percentuale</b>
-------------	---------------------	----------------------	--------------------

	<b>aziende</b>	<b>fraudolente</b>	
1979	3782	4	0.11%
1980	4010	10	0.25%
1981	4501	12	0.27%
1982	4718	19	0.40%
1983	5056	14	0.28%
1984	5100	16	0.31%
1985	5087	10	0.20%
1986	5234	21	0.40%
1987	5406	16	0.30%
1988	5129	19	0.37%
1989	4977	23	0.46%
1990	4893	18	0.37%
1991	4981	28	0.56%
1992	5209	28	0.54%
1993	5644	31	0.55%
1994	5966	24	0.40%
1995	6561	22	0.34%
1996	7095	34	0.48%
1997	7138	45	0.63%
1998	7042	56	0.80%
1999	7230	79	1.09%
2000	7153	92	1.29%
2001	6780	87	1.28%
2002	6475	81	1.25%
2003	6285	69	1.10%
2004	6218	60	0.96%
2005	6119	47	0.77%
2006	6130	35	0.57%
2007	6073	30	0.49%
2008	5817	27	0.46%
2009	5618	30	0.53%

2010	5585	26	0.47%
2011	5583	22	0.39%
2012	5814	21	0.36%
2013	5831	11	0.19%
2014	5786	4	0.07%
<b>Totale</b>	<b>206,026</b>	<b>1.171</b>	<b>0.57%</b>

Tabella 8: Distribuzione delle imprese fraudolente per anno nel periodo 1979-2008. (Fonte: Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019)

Gli AAER della SEC coprono i casi di frode contabile avvenuta già nel 1971, ma ci sono solo 13 società fraudolente negli anni prima del 1979, pertanto, sono stati omessi gli anni precedenti al 1979. Si considerano i casi di frode fino al 2014 perché la SEC impiega diversi anni per terminare le indagini su presunti casi di frode (Karpoff et al.2017). Come mostrato nella Tabella 8, nel periodo 1979-2014 sono stati rilevati 1.171 imprese fraudolente, ma la frequenza delle frodi rilevate è molto bassa, in genere inferiore all'1% di tutte le imprese all'anno. Inoltre, la frequenza osservata di frode diminuisce durante il periodo di prova 2003-2014. Ad esempio, la frequenza media delle frodi è dello 0,94% per il 2003-2005, 0,51% per il 2006-2008, 0,46% per il 2009-2011 e 0,21% per il 2012-2014. Se si presume che la vera incidenza della frode rimanga la stessa nel periodo 2003-2014, la frequenza decrescente della frode nella Tabella 8 suggerisce un aumento nel tempo della frode non rilevata, coerente con lo spostamento in diminuzione dell'applicazione della frode contabile da parte dei regolatori della Crisi finanziaria del 2008. Un'altra possibile ragione è che i regolatori impiegano molto tempo a completare le indagini sulla frode contabile, a causa delle risorse ridotte assegnate alle indagini sulla frode contabile, nel periodo post-crisi.

Poiché si inizia con un numero molto limitato di osservazioni di frode rilevate ogni anno, la presenza di un numero significativo di osservazioni di frode nascoste in un anno di prova potrebbe alterare completamente le inferenze nei test fuori campione. Per questo motivo, si utilizzano gli anni 2003-2008 come campione di test principale.

#### 4.3.3 Utilizzo dei dati finanziari grezzi

L'elenco delle voci di dati finanziari grezzi è selezionato in base al metodo Cecchini et al. (2010) che hanno identificato un elenco iniziale di 40 voci di dati finanziari grezzi utilizzati nella precedente ricerca di previsione delle frodi per costruire le variabili di

regressione. Cecchini et al. hanno mantenuto un elenco finale di 24 voci di dati finanziari grezzi dopo aver imposto il requisito che nessuna variabile grezza avesse più del 25% dei valori mancanti. Seguendo le stesse procedure di selezione del campione, si ottengono un elenco finale di 24 voci di dati finanziari grezzi durante il periodo di campionamento 1991-2008. La tabella 9 mostra l'elenco delle 40 voci di dati finanziari grezzi iniziali di Cecchini et al. (2010) nella colonna 1 e nella colonna 2 elenca i 24 elementi di dati grezzi conservati nell'analisi finale dopo l'eliminazione di variabili con più del 25% di valori mancanti. La colonna 3 mostra i 23 elementi di dati grezzi utilizzati per calcolare gli 11 rapporti finanziari da Dechow et al. (2011).

	40 voci di dati finanziari grezzi iniziali di Cecchini et al. (2010)	24 elementi di dati grezzi nella replica di Cecchini et al. (2010)	23 elementi di dati grezzi utilizzati nel modello Dechow et al. (2011)
<b>Voci di stato patrimoniale</b>			
<i>Contanti e investimenti a breve termine</i>	Si	Si	Si
<i>Totale crediti</i>	Si	Si	Si
<i>Crediti dubbi</i>	Si	-	-
<i>Totale rimanenze</i>	Si	Si	Si
<i>Totale investimenti a breve termine</i>	Si	Si	Si
<i>Totale attivo corrente</i>	Si	-	Si
<i>Totale immobili, impianti e macchinari</i>	Si	Si	Si
<i>Investimenti e anticipi</i>	Si	Si	Si
<i>Totale attivo</i>	Si	Si	Si
<i>Debiti verso fornitori</i>	-	-	Si

<i>Totale passività correnti</i>	Si	Si	Si
<i>Imposta sul reddito da pagare</i>	Si	Si	Si
<i>Impegni di locazione e leasing (minimo 1 anno)</i>	Si	-	-
<i>Totale passività correnti</i>	Si	Si	Si
<i>Debiti a lungo termine</i>	Si	Si	Si
<i>Impegni di locazione e leasing (minimo 2 anni)</i>	Si	-	-
<i>Impegni di locazione e leasing (minimo 3 anni)</i>	Si	-	-
<i>Impegni di locazione e leasing (minimo 4 anni)</i>	Si	-	-
<i>Impegni di locazione e leasing (minimo 5 anni)</i>	Si	-	-
<i>Totale passività</i>	Si	Si	Si
<i>Capitale sociale</i>	Si	Si	Si
<i>Totale azioni privilegiate</i>	Si	Si	Si
<i>Utili portati a nuovo</i>	Si	Si	-
<b>Voci di conto economico</b>			
<i>Ricavi delle vendite</i>	Si	Si	Si
<i>Costo del venduto</i>	Si	Si	Si
<i>Svalutazioni e</i>	Si	Si	-

<i>ammortamento</i>			
<i>Spese di ammortamento</i>	Si	-	-
<i>Spese di vendita, amministrative e generali</i>	Si	-	-
<i>Interessi e spese correlate</i>	Si	Si	-
<i>Interessi totali e reddito correlato</i>	Si	-	-
<i>Totale imposte sul reddito</i>	Si	Si	-
<i>Totale imposte differite</i>	Si	-	-
<i>Differenza A-B</i>	Si	Si	Si
<i>Utile/perdita</i>	Si	Si	-
<b>Voci del rendiconto finanziario</b>			
<i>Emissione di debito a lungo termine</i>	-	-	Si
<i>Vendita di azioni ordinarie e privilegiate</i>	-	-	Si
<i>Flusso di cassa netto delle attività di finanziamento</i>	Si	-	-
<b>Valore di mercato</b>			
<i>Prezzo di chiusura, annuale, fiscale</i>	Si	Si	Si
<i>Prezzo di chiusura, annuale, contabile</i>	Si	-	-
<i>Azioni ordinarie in circolazione</i>	Si	Si	Si



<b>Altri elementi</b>			
<i>Dipendenti</i>	Si	-	-
<i>Portafoglio ordini</i>	Si	-	-
<i>Piani pensionistici, rendimento previsto a lungo termine</i>	Si	-	-

Tabella 9. Elenco dei dati finanziari grezzi selezionati da Dechow et al. (2011) e Cecchini et al. (2010). (Fonte: Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019)

Sebbene vi sia una significativa sovrapposizione negli elementi di dati finanziari grezzi tra la replica di Cecchini et al. (2010) nella colonna 2 e Dechow et al. (2011) nella colonna 3, ci sono alcune differenze fondamentali. In primo luogo, l'elenco di variabili non elaborate di Dechow et al. nella colonna 3 contiene quattro voci di dati finanziari grezzi (ovvero, totale attività correnti, debiti verso fornitori, emissione di debito a lungo termine e vendita di azioni ordinarie e privilegiate) che sono esclusi dall'elenco dei dati grezzi di Cecchini et al. nella colonna 2. Queste quattro voci di dati finanziari grezzi vengono utilizzate per costruire rapporti finanziari utilizzati nel modello di base Dechow et al.. In secondo luogo, l'elenco di variabili non elaborate di Dechow et al. nella colonna 3 esclude cinque voci di dati finanziari grezzi incluse nell'elenco di Cecchini et al. nella colonna 2: utili non distribuiti, svalutazioni e ammortamento, totale interessi attivi e passivi, imposte sul reddito e utile/perdita. Infine, Cecchini et al. include utile/perdita come fattore normalizzante in quanto utilizza i rapporti e le variazioni anno su anno.

A causa delle differenze della selezione delle voci di dati finanziari grezzi, si combinano le voci di dati grezzi da entrambi i modelli per ottenere un campione finale di 28 voci di dati finanziari grezzi per tutti i successivi modelli di previsione delle frodi. In particolare, il modello Dechow et al. contiene 14 rapporti finanziari (gli 11 rapporti del modello base Dechow et al. più tre rapporti extra). Il modello Cecchini et al. costruisce il kernel finanziario utilizzando 28 voci di dati finanziari grezzi.

## 4.4 Risultati dei modelli selezionati

### 4.4.1 Modello Dechow et al.

La tabella 10 riporta i risultati della valutazione delle prestazioni fuori campione per il modello Dechow et al. relativo al periodo di prova 2003-2008, utilizzando le metriche di valutazione di AUC e NDCG@ k, riporta anche i t-test a coppie del modello di apprendimento d'insieme rispetto ad altri modelli tra parentesi. Tuttavia, poiché ci sono solo sei osservazioni per tali test t (bassa potenza), non ci si basa su di essi nelle inferenze seguenti e ci si concentra invece sull'entità delle differenze nelle due metriche di valutazione delle prestazioni tra i diversi modelli di rilevamento delle frodi.

Performance Metrics averaged over the test period 2003-2008					
		Metric one	Metric two		
Input Variables	Method	AUC	NDCG@ k	Sensitivity	Precision
<b>14 Financial ratios</b>	Logit	0.672	0.028	3.99%	2.63%
<b>28 Raw financial data items</b>	SVM-FK	0.626	0.020	2.53%	1.92%
	Logit	0.690	0.006	0.73%	0.85%
	RUSBoot	0.725	0.049	4.88%	4.48%

Tabella 10. Confronto delle prestazioni dei modelli di previsione delle frodi utilizzando le metriche delle prestazioni calcolate in media nel periodo 2003-2008. (Fonte: Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019)

Coerentemente con Dechow et al. (2011), l'AUC media per gli anni di test è di 0,672, molto superiore a 0,50, il valore soglia dell'AUC per ipotesi casuali, mentre l'NDCG @ k medio è 0,028. Il valore medio della sensibilità è del 3,99%, il che significa che il 3,99% di tutti i casi reali di frode nella popolazione viene catturato nel primo 1% delle osservazioni con le più alte probabilità di frode previste. Analogamente, il valore medio di precisione è 2,63%, il che significa che solo il 2,63% dell'1% superiore delle osservazioni con le più alte probabilità di frode previste sono casi reali di frode.

#### 4.4.2 Modello di Cecchini et al.

Cecchini et al. (2010) hanno sviluppato un metodo SVM innovativo basato su un kernel finanziario che mappa i dati finanziari grezzi in un elenco di rapporti predefiniti. Cecchini et al. (2010) mostra che il loro SVM-FK supera significativamente diversi modelli rappresentativi di previsione delle frodi nella contabilità, incluso quello di Dechow et al. (2011).

In questa sezione, si replicano, il metodo SVM-FK di Cecchini et al. utilizzando i dati utilizzati per il confronto migliorando la prestazione del modello, evitando due distorsioni del futuro. In primo luogo, per affrontare il problema dello squilibrio di classe, SVM-FK impiega l'SVM sensibile ai costi regolando il parametro del modello  $C^{+1}:C^{-1}$  (ovvero il rapporto tra il costo della classificazione errata delle frodi e la non frode). Quando si cerca il parametro ottimale  $C^{+1}:C^{-1}$  per massimizzare il valore di AUC, Cecchini et al. (2010) esegue direttamente la ricerca utilizzando il campione di prova anziché un campione di convalida di controllo. Per questo motivo, le procedure di implementazione di Cecchini et al. sono soggette ad una propensione al futuro. In particolare, si forma il modello SVM-FK utilizzando 1991-1999 e si convalida il modello utilizzando 2000-2001 per gli anni di prova 2003-2008. Si usano due anni invece di un anno per la convalida a causa della bassa frequenza di frode in un anno tipico. Dopo aver determinato il parametro ottimale  $C^{+1}:C^{-1}$  (20 nel campione), si forma il modello e si testano le sue prestazioni. In particolare, si utilizza il periodo di formazione 1991-2001 per l'anno di prova 2003, 1991-2002 per l'anno di prova 2004 e così via. In secondo luogo, si differisce da Cecchini et al. (2010) in quanto si utilizzano tutti gli anni dell'azienda in un periodo di prova per eseguire la valutazione delle prestazioni fuori campione. Cecchini et al. (2010) eseguono l'addestramento, la convalida e la valutazione del modello fuori campione solo dopo aver ottenuto, per una serie di anni società fraudolente e tutti gli anni società non fraudolente, abbinati nello stesso anno. Poiché i modelli SVM-FK richiedono molto tempo per la formazione e la convalida per set di dati di grandi dimensioni, è opportuno utilizzare un campione abbinato di frodi e non frodi durante il periodo di formazione.

Tuttavia, è problematico utilizzare solo gli anni di attività fraudolente e non fraudolente abbinati in un anno di prova per valutare le prestazioni fuori campione del modello SVM-FK, in quanto ciò potrebbe invitare a distorsioni per il futuro, realizzando implementazioni temporali problematiche. In particolare, poiché sono necessari in

media due anni per la divulgazione iniziale della frode contabile (Dyck et al. 2010), un decisore rilevante (ad esempio un investitore) non sa al momento della previsione se i bilanci di una società in un anno industriale sono fraudolenti o no in un anno di prova. Pertanto, il decisore non può associare un'impresa fraudolenta a un'impresa non fraudolenta nell'anno di prova, perciò un approccio più appropriato alla valutazione delle prestazioni fuori campione è quello di valutare le prestazioni fuori campione di SVM-FK utilizzando l'intera popolazione di attività nel periodo di prova. Per questo motivo, la replica di Cecchini et al. (2010) utilizza un campione abbinato di attività fraudolenti e non fraudolenti per la formazione e la convalida, ma utilizza l'intera popolazione di attività nel periodo di prova 2003-2008 per valutare le prestazioni fuori campione del modello SVM-FK.

Queste distinzioni sembrano essere fondamentali nella valutazione delle prestazioni fuori campione del modello SVM-FK. In particolare, i risultati non tabulati mostrano che il campione di imprese fraudolente e non fraudolente abbinate costituisce solo il 22,61% (6.984 / 30.883) della popolazione di imprese fraudolente e non fraudolente nel periodo di prova 2003-2008. 237 (0,77%) delle 30.883 osservazioni nel campione completo del periodo di prova 2003-2008 sono veri casi di frode. Al contrario, per il campione corrispondente di frode e non frode basato sul periodo di prova 2003-2008, 237 (3,39%) delle 6.984 osservazioni sono casi effettivi di frode. La tabella 11 mostra che l'AUC media per il modello SVM-FK è di 0,673 utilizzando un campione abbinato di osservazioni fraudolente e non fraudolente nel periodo di prova 2003-2008.

<b>Performance Metrics averaged over the test period 2003-2008</b>					
		<b>Metric one</b>	<b>Metric two</b>		
<b>Input Variables</b>	<b>Method</b>	<b>AUC</b>	<b>NDCG@ k</b>	<b>Sensitivity</b>	<b>Precision</b>
14 Financial Ratios	Logit	0.672	0.028	3.99%	2.63%
28 Raw Financial data items	SVM-FK	0.626	0.020	2.53%	1.92%
	Logit	0.690	0.006	0.73%	0.85%
	RUSBoot	0.725	0.049	4.88%	4.48%
	SVM	0.680	0.016	1.69%	1.90%
	SVM-FK	0.673	0.162	4.58%	16.44%

	(Matched)				
11 Financial Ratios	Logit	0.649	0.025	3.49%	2.26%

Tabella 11 (appendice online) La tabella mostra le prestazioni dei modelli di previsione delle frodi (modelli (1) - (4) nella tabella 10 e tre modelli aggiuntivi non tabulati nel documento, tra cui: (5) SVM kernel lineare basata sui 28 dati finanziari grezzi, (6) SVM-FK utilizzando un campione abbinato di osservazioni fraudolente e non fraudolente negli anni di test e (7) modello di base di Dechow et al. basato sugli 11 rapporti finanziari) utilizzando le metriche di rendimento calcolate in media nel periodo di prova 2003-2008. (Fonte: Appendice online – Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang Bao, Bin Ke, Bin Li, Y. Julia Yu, Jie Zhang 2019)

Questo numero diminuisce in modo significativo quando viene utilizzata l'intera popolazione nel periodo 2003-2008. In particolare, come mostrato nella Tabella 11, l'AUC medio, dopo aver corretto i due pregiudizi, è solo 0,626, persino inferiore all'AUC medio del modello di Dechow et al.. Usando NDCG@ k come criterio di valutazione alternativo, scopriamo che il valore medio di NDCG@ k per la nostra replica del metodo SVM-FK di Cecchini et al. è solo 0,020, anche inferiore alla media NDCG@ k del modello Dechow et al. Per l'1% superiore degli anni di attività fraudolenta previsti dal modello SVM-FK nel periodo di prova 2003-2008, i valori medi di sensibilità e precisione sono rispettivamente del 2,53% e dell'1,92%.

Utilizzando AUC o NDCG@ k come metrica di valutazione delle prestazioni, nel complesso, le prestazioni di Cecchini et al. è più debole delle prestazioni del modello Dechow et al..

#### **4.4.3. Modello apprendimento d'insieme**

Nei successivi paragrafi, si esaminerà se è possibile migliorare le prestazioni della previsione delle frodi utilizzando dati finanziari grezzi abbinati a un metodo di apprendimento automatico più potente, l'apprendimento d'insieme. Per vedere più chiaramente il valore della combinazione di dati grezzi con l'apprendimento d'insieme, si suddivide la valutazione in tre fasi. Innanzitutto, si esaminano le prestazioni di previsione continuando a utilizzare la regressione logistica ma modificando l'input del modello dai 14 rapporti finanziari alle 28 voci di dati finanziari grezzi. In secondo luogo, si esaminano le prestazioni di previsione delle frodi del modello proposto utilizzando sia i 28 elementi di dati grezzi sia il metodo di apprendimento d'insieme. In terzo luogo, si esaminano le prestazioni di previsione delle frodi utilizzando il metodo di

apprendimento d'insieme ma modificando l'input del modello dai 28 elementi di dati grezzi ai 14 rapporti finanziari o la combinazione dei 14 rapporti finanziari e i 28 elementi di dati grezzi.

#### **4.4.3.1 Metodo modello di regressione logistica con dati finanziari grezzi**

La Tabella 10 mostra le prestazioni di previsione del modello di regressione logistica in base alle 28 voci di dati finanziari grezzi.

L'AUC medio per il modello di regressione logistica basato sulle 28 voci di dati finanziari grezzi è 0,690, superiore all'AUC medio sia del modello di Dechow et al. che di Cecchini et al.. Tuttavia, il valore medio di NDCG@ k per la regressione logistica in base ai 28 elementi di dati grezzi è solo 0,006, inferiore ai valori medi di NDCG@ k per Dechow et al. e Cecchini et al. Nel complesso, i risultati sono contrastanti e non è possibile stabilire se l'utilizzo di dati grezzi da soli senza adottare un metodo di apprendimento automatico più avanzato possano migliorare le prestazioni di previsione.

#### **4.4.3.2 Metodo apprendimento d'insieme con dati finanziari grezzi**

Limitando alle stesse 28 voci di dati finanziari grezzi, si esaminerà se è possibile migliorare le prestazioni di previsione delle frodi fuori campione utilizzando il metodo di *data mining* più avanzato, l'apprendimento d'insieme. Sebbene ogni algoritmo abbia alcuni parametri che richiedono una regolazione fine, vale la pena notare che *AdaBoost* (e varianti come *RUSBoost*) è considerato uno dei migliori algoritmi di classificazione pronti all'uso. *RUSBoost* ha due parametri principali da regolare: il numero di alberi decisionali e la complessità degli alberi. In particolare, si forma il modello *RUSBoost* utilizzando il periodo 1991-1999 e si convalida il modello utilizzando gli anni 2000-2001. Si imposta il numero di alberi su 3000 perché è stato scoperto che le prestazioni dei modelli *RUSBoost* tendono a diventare stabili dopo 3000 alberi creati. Teoricamente, ci sono diversi parametri che possono essere usati per controllare la complessità degli alberi, come la profondità degli alberi o il numero minimo di campioni richiesto su una foglia di un albero (come *minleaf*). Si sceglie di utilizzare il parametro "*minleaf*" poiché l'implementazione pratica dell'albero decisionale in *Matlab* lo supporta come parametro. Si imposta il parametro "*minleaf*" su 5, che è il miglior valore nell'intervallo (1, 200), per massimizzare le metriche delle prestazioni di AUC e NDCG@ k nel periodo di convalida 2000-2001.

Oltre al suddetto importante parametro, si considerano anche due parametri aggiuntivi: "*learning rate*" e "*RatioToSmallest*". Il "*learning rate*" (tasso di apprendimento)

corrisponde alla velocità con cui l'errore viene corretto da ciascun albero al successivo, è compreso tra 0 e 1 e lo si imposta su 0,1 perché questa scelta consente generalmente al modello d'insieme di ridurre la varianza complessiva del modello finale. L'altro parametro, "*RatioToSmallest*" (rapporto al minimo) è un parametro specifico di *RUSBoost* che distingue il rapporto tra il numero di casi non fraudolenti e casi fraudolenti durante l'esecuzione di RUS (*Random Under Sampling*). "*RatioToSmallest*" è generalmente impostato su 1: 1.

La tabella 12 riporta le prestazioni fuori campione del modello di apprendimento d'insieme e modello di Dechow et al. in base ai dati finanziari grezzi nel periodo di prova 2003-2008.

<b>Metodo</b>	<b>AUC</b>	<b>NDCG@ k</b>	<b>Sensibilità</b>	<b>Precisione</b>
Apprendimento d'insieme	0,725	0,049	4,88%	4,48%
Dechow et al	0,672	0,028	3,99%	2,63%

Tabella 12. Confronto Apprendimento d'insieme e metodo di Dechow et al. (Fonte: personale, dati estratti da "Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019")

L'AUC medio per il metodo di apprendimento d'insieme è 0,725, molto più alto dell'AUC medio per il modello di riferimento migliore, il modello Dechow et al. (0.672). Usando NDCG@ k come criterio di valutazione alternativo, si scopre che il valore medio di NDCG@ k per il metodo di apprendimento d'insieme è 0,049, maggiore del valore medio di NDCG@ k di Dechow et al. (0,028). I valori medi di sensibilità e precisione per il modello di apprendimento d'insieme sono rispettivamente del 4,88% e del 4,48%; al contrario, i valori corrispondenti di Dechow et al. sono rispettivamente del 3,99% e del 2,63%. Nel complesso, questi risultati suggeriscono che il modello proposto, che combina dati finanziari grezzi con il più potente metodo di apprendimento d'insieme, supera i due modelli di riferimento. Per meglio apprezzare la rilevanza economica nelle prestazioni differenziali dei vari modelli di previsione per il periodo di prova 2003-2008, si calcola anche il numero di osservazioni di frode reali identificate utilizzando l'approccio NDCG@ k dove k = 1%. Si scopre che il modello di apprendimento d'insieme, ha identificato un totale di 16 casi di frode nel periodo di prova 2003-2008. Al contrario, la cifra comparabile è 9 per Dechow et al. e 7 per Cecchini et al..

<b>Modello</b>	<b>N° casi di frode identificati con</b>
----------------	--

	<b>approccio NDCG k</b>
Dechow et al.	9
Cecchini et al.	7
Apprendimento d'insieme	16

Tabella 13. Casi di frode identificati dai vari modelli. (Fonte: personale, dati estratti da "Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019")

Questi risultati suggeriscono che le differenze nelle prestazioni del modello di apprendimento d'insieme rispetto ai due modelli di riferimento sono anche economicamente significative.

#### **4.4.3.3 Rapporti finanziari e dati grezzi utilizzando il metodo di apprendimento d'insieme**

Si esamina inoltre se è possibile migliorare le prestazioni del metodo di apprendimento d'insieme utilizzando solo i 14 rapporti o utilizzando contemporaneamente sia i 28 dati grezzi che i 14 rapporti. La Tabella 14 riporta le statistiche sulle prestazioni fuori campione per questi due modelli alternativi.

<b>Performance Metrics averaged over the test period 2003-2008</b>					
		<b>Metric One</b>	<b>Metric two</b>		
<b>Input Variables</b>	<b>Method</b>	<b>AUC</b>	<b>NDCG@ k</b>	<b>Sensivity</b>	<b>Precision</b>
28 Raw financial data items	RUSBoost	0.725	0.049	4.88%	4.48%
14 Financial Ratios	RUSBoost	0.659	0.017	2.03%	1.69%
14 Financial Ratios +28 Raw financial data items	RUSBoost	0.696	0.035	3.19%	2.54%
All 294 Raw Financial data Items	RUSBoost	0.692	0.015	1.92%	1.41%



Tabella 14. Le metriche di valutazione delle prestazioni fuori campione: il metodo di apprendimento d'insieme basato su diversi set di variabili di input. (Fonte: Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019)

Non si trovano prove del fatto che i due modelli di apprendimento d'insieme alternativi superino il modello di apprendimento d'insieme basato esclusivamente sui 28 elementi di dati grezzi. Ciò perché il valore dell'AUC è di 0,659 e 0,696 rispetto allo 0,725 del modello basato solo sui 28 dati grezzi e allo stesso tempo l'NDCG@ k è di 0,017 e 0,035 rispetto allo 0,049 del modello di partenza.

Questa prova è coerente con la congettura che una volta considerati i 28 elementi di dati grezzi associati a un metodo di apprendimento automatico flessibile e potente, i rapporti costruiti dagli stessi elementi di dati grezzi non sono più utili in modo incrementale nella previsione delle frodi.

#### **4.4.3.4 Metodo di apprendimento d'insieme con maggiori dati finanziari grezzi**

Finora le analisi hanno utilizzato solo 28 voci di dati finanziari grezzi e rapporti contabili identificati da esperti umani come importanti nello spiegare le frodi contabili. Queste 28 voci di dati grezzi rappresentano solo una piccola parte delle voci di dati disponibili dei tre principali documentai di bilancio, ci chiediamo quindi se sia possibile migliorare ulteriormente le prestazioni del metodo di apprendimento d'insieme includendo più elementi di dati grezzi. Viene adottato un approccio di "*brute force*<sup>28</sup>" includendo nel modello d'insieme tutte le voci di dati di bilancio grezzi disponibili dal file *Compustat Fundamental* che soddisfano il campione. Si identificano un totale di 266 ulteriori elementi di dati grezzi dai tre documenti, che sono applicabili alle società industriali durante il periodo campione 1991-2008. Poiché il metodo di apprendimento d'insieme è in grado di gestire le osservazioni con valori mancanti, non si impone alcuna limitazione alle voci di bilancio per le quali manca una parte dei dati.

L'ultima riga della tabella 14 riporta i risultati. Il valore medio di AUC è inferiore per questo modello di apprendimento d'insieme, nonostante sia più completo, rispetto al metodo d'insieme basato sui 28 elementi di dati grezzi della Tabella 11 (0,692 vs. 0,725). Il valore medio di NDCG@ k è molto più basso per questo modello di apprendimento d'insieme più completo, rispetto al metodo di apprendimento d'insieme basato sui 28 elementi di dati grezzi (0,015 vs. 0,049). Questi risultati suggeriscono che l'inclusione di un gran numero di voci di dati finanziari grezzi nel miglior modello di previsione delle

---

<sup>28</sup> Ricerca esaustiva

frodi, senza una chiara guida teorica, non aiuta a migliorare le prestazioni del modello. Questa scoperta suggerisce che la guida teorica è ancora importante nella selezione dell'input del modello, anche quando si adottano potenti metodi di apprendimento automatico come l'apprendimento dell'insieme.

#### 4.4.3.5 Criticità del metodo di apprendimento d'insieme

Uno svantaggio noto di molti metodi di apprendimento automatico è la mancanza di trasparenza riguardo al funzionamento interno di tali modelli. Mentre i singoli alberi decisionali possono essere interpretati facilmente visualizzando la struttura degli alberi, i metodi di apprendimento d'insieme comprendono centinaia di alberi e quindi non possono essere facilmente interpretati dall'ispezione visiva dei singoli alberi.

Sono state proposte alcune tecniche per aiutare a far luce sui driver di prestazione significativi dei modelli d'insieme, stimando l'importanza di varie caratteristiche nella previsione di frode. Si utilizza la funzione "*predictorImportance*<sup>29</sup>" implementata in Matlab per stimare l'importanza dei 28 elementi di dati finanziari grezzi utilizzati nel modello di apprendimento d'insieme. Nello specifico, gli alberi decisionali individuali eseguono intrinsecamente la selezione delle caratteristiche selezionando i punti di divisione appropriati<sup>30</sup>. Queste informazioni possono essere utilizzate per misurare l'importanza di ciascuna caratteristica: il cambiamento di impurità (una misura della qualità della divisione) dovuto alla divisione su una caratteristica indica la sua importanza (Breiman, Friedman, Stone, Olshen 1984). Questa nozione di importanza può essere estesa agli insiemi di alberi decisionali semplicemente facendo la media dell'importanza delle caratteristiche di ogni albero.

La tabella 15 riporta le statistiche descrittive sull'importanza media di 28 voci di dati grezzi per il modello di apprendimento d'insieme per i sei anni di prova.

<b>Rank</b>	<b>28 voci dei dati finanziari grezzi</b>	<b>Valore medio dell'importanza di una caratteristica per il periodo di</b>
-------------	---	---

<sup>29</sup> Stime dell'importanza del perditore

<sup>30</sup> Se ad esempio si hanno 3 caratteristiche, si hanno 3 divisioni candidate. Si calcola per ognuna di essa quanta accuratezza ogni divisione costerà (usando una funzione) e si sceglie quella con costo migliore.

		<b>prova 2003- 2008</b>
1	<i>Azioni ordinarie in circolazione</i>	1.448
2	<i>Totale attivo corrente</i>	1.362
3	<i>Vendita di azioni ordinarie e privilegiate</i>	1.324
4	<i>Totale immobili, impianti e macchinari</i>	1.289
5	<i>Fornitori</i>	1.237
6	<i>Contanti e investimenti a breve termine</i>	1.210
7	<i>Prezzo di chiusura delle azioni rispetto all'anno fiscale</i>	1.146
8	<i>Utili portati a nuovo</i>	1.119
9	<i>Rimanenze totali</i>	1.064
10	<i>Capitale sociale</i>	1.054
11	<i>Totali passività correnti</i>	1.042
12	<i>Svalutazioni e ammortamenti</i>	1.041
13	<i>Totale crediti</i>	0.982
14	<i>Costo dei beni venduti</i>	0.968
15	<i>Totale attivo</i>	0.873

16	<i>Emissione di debito a lungo termine</i>	0.801
17	<i>Differenza A-B</i>	0.788
18	<i>Totale debiti a lungo termine</i>	0.784
19	<i>Totale interessi e spese relative</i>	0.731
20	<i>Totale imposte sul reddito</i>	0.712
21	<i>Totale passività correnti</i>	0.704
22	<i>Ricavi delle vendite</i>	0.625
23	<i>Imposte correnti</i>	0.592
24	<i>Investimenti e anticipi</i>	0.588
25	<i>Totale passività</i>	0.546
26	<i>Totale investimenti a breve termine</i>	0.476
27	<i>Utile/Perdita</i>	0.371
28	<i>Azioni privilegiate</i>	0.247

Tabella 15. Mostra l'importanza della caratteristica dei 28 elementi di dati grezzi utilizzati nel modello RUSBoost. (Fonte: Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019)

I 28 elementi di dati grezzi sono ordinati dal più alto al più basso in base all'importanza media delle funzionalità. Le 10 principali caratteristiche che contribuiscono al rendimento del modello di apprendimento d'insieme sono elencate di seguito, a partire dalle più importanti:

- azioni comuni in circolazione;
- totale attività correnti;
- vendita di azioni ordinarie e privilegiate;

- totale immobili, impianti e macchinari;
- debiti verso fornitori;
- liquidità e investimenti a breve termine;
- prezzo di chiusura delle azioni rispetto all'anno fiscale
- utili non distribuiti;
- totale inventari;
- totale capitale sociale.

Si può notare che le azioni ordinarie in circolazione e il prezzo di chiusura delle azioni rispetto all'anno fiscale forniscono informazioni significative per la previsione delle frodi. Si sospetta che le azioni ordinarie in circolazione siano utili nel prevedere le frodi contabili semplicemente perché le società che effettuano dichiarazioni inesatte spesso emettono azioni ordinarie. Allo stesso modo, il prezzo di chiusura delle azioni rispetto all'anno fiscale fornisce informazioni preziose sulla probabilità di frode, a causa di scambi durante il periodo di errore sia da parte dei dipendenti dell'azienda che di altri stakeholder correlati.

#### **4.5 Considerazioni finali**

La frode contabile è estremamente difficile da rilevare, pertanto, un'importante area di ricerca contabile potrebbe essere lo sviluppo di metodi efficaci per rilevarla tempestivamente, limitando in tal modo l'entità del danno ad essa correlato.

Negli anni si è sviluppato un nuovo modello di previsione delle frodi fuori campione basato su un campione di società statunitensi quotate in borsa nel periodo 1991-2008. Per preservare la natura della previsione di frode, si utilizzano gli ultimi sei anni del periodo di campionamento, 2003-2008, come periodo di prova fuori campione e gli anni precedenti come periodo di addestramento. Per mitigare il potenziale orientamento al futuro, è necessario inoltre un divario minimo di 24 mesi tra l'annuncio dei risultati finanziari per l'ultimo periodo di formazione e l'annuncio dei risultati finanziari di un anno di prova. Viene fatto perché ci vogliono in media 24 mesi per rivelare una frode.

In linea con la ricerca esistente, si utilizzano solo dati finanziari facilmente disponibili come input per la previsione delle frodi (Dyck et al. 2010). Tuttavia, ci si allontana dalla maggior parte delle ricerche esistenti in materia contabile, in diversi modi importanti. Innanzitutto, si prevede la frode al di fuori del campione piuttosto che ricercare le cause della frode all'interno del campione. In secondo luogo, si utilizzano i dati finanziari grezzi degli schemi di bilancio per prevedere la frode, al contrario, la ricerca esistente di

solito utilizza indici finanziari identificati da esperti umani. Terzo, si utilizza l'apprendimento d'insieme, uno dei paradigmi più avanzati nell'apprendimento automatico, per la previsione delle frodi piuttosto che la regressione logistica comunemente usata. Infine, si introduce un nuovo approccio, comunemente usato per classificare i problemi, per valutare le prestazioni dei modelli di previsione delle frodi, denominato “*Normalized Discounted Cumulative Gain*” nella posizione k (NDCG @ k). Nonostante ci siano numerose voci di dati finanziari grezzi, si limitano le analisi alle 28 voci di dati grezzi utilizzate da Cecchini et al. (2010) e Dechow et al. (2011) al fine di confrontare le prestazioni del modello di previsione delle frodi proposto con quello dei metodi di previsione delle frodi più tradizionali.

Si utilizzano per il confronto due modelli di riferimento. Innanzitutto, si segue Dechow et al. (2011) che utilizza un modello logistico di previsione delle frodi basato su 14 rapporti finanziari derivati dalle 28 voci di dati grezzi; il secondo è il modello sviluppato da Cecchini et al. (2010) basato su macchine vettoriali di supporto con un kernel finanziario (SVM-FK) che mappa i 28 elementi di dati finanziari grezzi in un insieme più ampio di rapporti finanziari e cambiamenti degli stessi.

Si scopre che le prestazioni fuori campione di entrambi i modelli di riferimento sono buone ma le prestazioni di Dechow et al. sono migliori delle prestazioni di Cecchini et al..

<b>Modello</b>	<b>AUC</b>	<b>NDCG@ k</b>
Dechow et al. basato su 14 rapporti finanziari	0,672	0,028
Cecchini et al. basato su 28 dati finanziari grezzi	0,626	0,020

Tabella 16. Risultati dell'applicazione del metodo AUC e NDCG@ k ai modelli Dechow et al. e Cecchin et al. fuori campione. (Fonte: personale, dati estratti da “Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019”)

Ancora più importante, è il fatto che il modello di apprendimento d'insieme basato sulle 28 voci di dati finanziari grezzi superi direttamente i due modelli di riferimento.

<b>Modello</b>	<b>AUC</b>	<b>NDCG@ k</b>
Dechow et al. basato su 28 voci di dati grezzi	0,690	0,006
Apprendimento d'insieme basato sui 28 dati finanziari	0,725	0,049

grezzi		
--------	--	--

Tabella 17. Risultati dell'applicazione del metodo AUC e NDCG@ k ai modelli Dechow et al. e apprendimento automatico basato sulle 28 voci di dati finanziari grezzi. (Fonte: personale, dati estratti da "Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019")

Tuttavia, non si trova alcuna prova del fatto che un semplice modello di regressione logistica basato su dati grezzi o un modello di apprendimento d'insieme basato sui 14 rapporti finanziari, o la combinazione dei 14 rapporti finanziari e dei 28 elementi di dati grezzi, superi il modello di apprendimento d'insieme basato solo sui 28 elementi di dati grezzi. Questi risultati suggeriscono che Dechow et al. basato sui rapporti finanziari identificati dagli esperti umani non ha utilizzato appieno le preziose informazioni contenute nei dati finanziari grezzi e inoltre, si mostra che è possibile estrarre informazioni predittive più utili dai dati grezzi costruendo un modello di apprendimento automatico più avanzato progettato per utilizzare tali dati.

Poiché le 28 voci di dati grezzi rappresentano solo una piccola parte delle centinaia di possibili voci di dati finanziari grezzi che emergono dal sistema contabile, si esamina anche se l'inclusione di tutte le voci di dati finanziari grezzi ammissibili e prontamente disponibili dei tre documenti di bilancio migliorano ulteriormente le prestazioni del modello di apprendimento d'insieme. Non è possibile provare tale affermazione, in quanto aggiungendo più elementi di dati grezzi, senza alcuna teoria supplementare, non porta ad un miglioramento.

<b>Modello</b>	<b>AUC</b>	<b>NDCG@ k</b>
Apprendimento automatico basato sui 28 dati finanziari grezzi	0,725	0,049
Apprendimento automatico basato sui 14 indici finanziari	0,659	0,017
Apprendimento automatico basato sui 14 indici finanziari e 28 dati finanziari grezzi	0,696	0,035
Apprendimento automatico	0,692	0,015

basato su 294 dati finanziari grezzi		
---	--	--

Tabella 18. Modello di apprendimento automatico nelle varianti di input. (Fonte: personale, dati estratti da "Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach, Yang, Bin, Bin, Yu, Zhang 2019")



## CONCLUSIONE

In questo elaborato si è voluto analizzare il fenomeno dei *Big Data* in abito di frode contabile.

In particolare attraverso l'analisi dei documenti selezionati e alle risposte alle domande di ricerca è stato possibile visionare il fenomeno da 3 punti di vista importanti.

Il primo è il ruolo dei *Big Data* in ambito contabile dove è stato riscontrato che il loro utilizzo è molto importante ma allo stesso tempo i professionisti devono tenere in considerazione anche la loro esperienza e il giudizio professionale. Questo perché, se vengono considerati solo i risultati dei *Big Data* per prendere decisioni, si potrebbe creare una dipendenza nel loro utilizzo, i dati non verrebbero messi in discussione e verrebbe trascurato lo scetticismo professionale.

Il suo ruolo è importante in quanto viene considerata come la prima figura che potrebbe rilevare la frode in una registrazione contabile, in fase di chiusura di bilancio o in fase di contabilità forense in un modo più digitale grazie all'utilizzo dei *Big Data*, abbandonando il foglio di calcolo tradizionale, troppo semplice per lo svolgimento di determinate attività.

Il secondo ruolo è la figura del revisore contabile. Attualmente i *Big Data* non sono molto utilizzati in ambito di revisione contabile ma si sostiene che svolgeranno un ruolo importante nell'*auditing* in quanto integrano le prove tradizionali con informazioni sufficienti, affidabili e pertinenti e saranno utilizzati per valutare elementi probativi interni e offriranno agli auditor opportunità uniche.

Le aziende stanno investendo in *Big Data* per migliorare il proprio processo decisionale e si aspettano che i revisori possano sfruttarli per migliorare anche l'efficacia e l'efficienza degli *audit* ma anche se i processi automatizzati fossero oggettivamente superiori a quelli manuali, gli esseri umani potrebbero comunque fidarsi e preferire i giudizi umani rispetto a quelli automatizzati e anonimi.

In ultimo sono stati analizzati una serie di modelli di *Big Data* per vedere se sono efficaci ed efficienti nella rilevazione della frode.

Gli strumenti di *Big Data* hanno un potenziale per rendere il processo di rilevazione delle transazioni fraudolente più efficace ed efficiente ma gli investigatori devono essere in grado di scegliere il modello più adatto al loro caso, avere un'adeguata formazione per utilizzarlo e affidarsi ad esso per il rilevamento della frode ma allo stesso tempo riconoscere i suoi limiti ed esprimere pareri personali, come nella rilevazione manuale.

Incorporare i *Big Data* come prove aggiuntive aiutano il rilevamento di anomalie e la previsione di frodi, migliorando la qualità della prestazione. I *Big Data* e le analisi di business ora attraversano quasi tutti gli aspetti del processo decisionale e delle strategie aziendali delle grandi aziende.

Infine è stato fatto un raffronto tra due modelli di *Big Data* già analizzati dalla letteratura e uno nuovo. Si è potuto riscontrare che più il modello è automatizzato e preciso, più sarà efficace ed efficiente nella previsione della frode. Il nuovo modello infatti riesce a prevenire più casi di frode rispetto ai due modelli di riferimento che non sono molto complessi ma comunque precisi.

Il fenomeno dei *Big Data* e frode contabile è un mondo ancora tutto da scoprire e dovrebbe essere più sviluppato in quanto l'argomento è sempre in più diffusione.

## BIBLIOGRAFIA

- Abou-El-Sood H., Kotb A., Allam A. (2015), "Exploring auditors' perceptions of the usage and importance of audit information technology", *International Journal of Auditing*, **19-3**:252-266;
- Albekov A.U. Vovchenko N.G., Andreeva O.A., Sichev RA. (2017). "Block Chain and Financial Controlling in the System of Technological Provision of Large Corporations Economic Security" *European Research Studies Journal*, **20(3B)**:3-12
- Albrecht W.S., Albrecht C.C., Albrecht C.D. (2009), "Fraud Examination", 3rd ed., Thomson/South-Western;
- Albrecht WS, Albrecht CC, Albrecht CO, Zimbelman MF. (2012) "Fraud examination" 4th ed. South-Western Cengage Learning: Mason;
- Alles, M. (2013) "Developing a Framework for the Role of Big Data in Auditing: A Synthesis of the Literature" *Working paper, Rutgers, The State University of New Jersey*;
- Alles M., Gray G. (2016), "Incorporating Big Data in audits: Identifying inhibitors and a research agenda to address those inhibitors", *International Journal of Accounting Information Systems*, **22**: 44-59;
- Amani F.A., Fadlalla A.M., (2017), "Data mining applications in accounting: A review of the literature and organizing framework", *International Journal of Accounting Information Systems*, **24**:32-58;
- American Institute of Certified Public Accountants (AICPA 2002), "Consideration of Fraud in a Financial Statement Audit" *Statement on Auditing Standards 99* New York, NY: AICPA;
- American Institute of Certified Public Accountants (AICPA 2011), "Statement on Auditing Standards (SAS) Nos. 122–124: No. 122, Statements on Auditing Standards: Clarification and Recodification; No. 123, Omnibus Statement on Auditing Standards; No. 124, Financial Statements Prepared in Accordance With a Financial Reporting Framework Generally Accepted in Another Country;
- American Institute of Certified Public Accountants (AICPA 2013) "Clarified statements on auditing standards";
- American Institute of Certified Public Accountants (AICPA 2014). "Reimagining auditing in a wired world (White Paper)";

- Appelbaum D.A., Kogan A., Vasarhelyi M.A., (2018) “Analytical procedures in external auditing: A comprehensive literature survey and framework for external audit analytics”, *Journal of Accounting Literature*, **40**:83-101;
- Appelbaum D.A., Kogan A., Vasarhelyi M.A. (2017), “Big data and analytics in the modern audit engagement: Research needs”, *Auditing: A Journal of Practice and Theory*, **36-4**:1-27;
- Asare S. K., Wright A. M. (2004) “The effectiveness of alternate risk assessment and program planning tools in a fraud setting” *Contemporary Accounting Research* **21 (2)**: 325–352;
- Association of Certified Fraud Examiners (ACFE 2012) “Report to the nation on occupational fraud and abuse”;
- Association of Certified Fraud Examiners (ACFE 2013), “Report to the nations on occupational fraud and abuse” Global Fraud Study;
- Association of Certified Fraud Examiners (ACFE 2014) “Report to the nation on occupational fraud and abuse”;
- Association of Certified Fraud Examiners (ACFE) (2016), “Report to the nations on occupational fraud and abuse”;
- Association of Certified Fraud Examiners (ACFE 2010). Fraud examiners manual US;
- Atkins P. S., Bondi B. J. (2008) “Evaluating the Mission: A Critical Review of the History and Evolution of the SEC Enforcement Program.” *Fordham Journal of Corporate and Financial Law* **13**: 367-417;
- Baker J, Burkman J, Jones D. (2009) “Using visual representations of data to enhance sensemaking in data exploration tasks” *Journal of the Association for Information Systems*, **10(7)**:533–59.
- Baldwin A.A., Brown C.E., Trinkle, B.S. (2006), “Opportunities for artificial intelligence development in the accounting domain: the case for auditing”, *Intelligent Systems in Accounting, Finance and Management*, **14 (3)**: 77-86.
- Bao Y., Ke B., Li B., Yu Y.J., Zhang J., (2020) “Detecting Accounting Fraud in Publicly Traded U.S. Firms Using a Machine Learning Approach”, *Journal of Accounting Research*, **58**:199-235;

- Bay, S., Kumaraswamy, K., Anderle, M.G., Kumar, R., Steier, D.M., (2006) "Large scale detection of irregularities in accounting data" *Proceedings of the 6th IEEE International Conference on Data Mining (ICDM'06)*, Hong Kong, HK;
- Bawden, D (2001) "Information and digital literacies: A review of concepts" *Journal of Documentation* **57**: 218–259;
- Beasley M. S., Carcello J. V., Hermanson D. R., (1999) "Fraudulent Financial Reporting: 1987-1997: An Analysis of U.S. Public Companies" *Sponsored by the Committee of Sponsoring Organizations of the Treadway Commission (COSO)*;
- Beasley, M. S., Carcello J. V., Hermanson D. R., Neal T. L. (2010) "Fraudulent Financial Reporting: 1998-2007: An Analysis of U.S. Public Companies." *Sponsored by the Committee of Sponsoring Organizations of the Treadway Commission (COSO)*;
- Becker E.A. (1980), "The evolution of financial auditing in the United States", *Baylor Business Studies*, **11(2)**:37-54;
- Bedard J. C., Biggs S. R. (1991a) "Pattern recognition, hypotheses generation, and auditor performance in an analytical task" *The Accounting Review* **66 (3)**: 622–642;
- Bell T. B., Carcello J. V. (2000); "A decision aid for assessing the likelihood of fraudulent financial reporting" *Auditing: A Journal of Practice & Theory*, **19(1)**:169-184;
- Bella B., Eloff J.H., Olivier M.S., (2009) "A fraud management system architecture for next-generation networks" *Forensic Science International* **185**:51–58;
- Beneish M. D. (1997) "Detecting GAAP Violation: Implications for Assessing Earnings Management among Firms with Extreme Financial Performance." *Journal of Accounting and Public Policy* **16**: 271-309;
- Beneish M. D. (1999) "The Detection of Earnings Manipulation." *Financial Analysts Journal* **55**: 24-36;
- Bierstaker J., Janvrin D., Lowe D.J. (2014), "What factors influence auditors' use of computerassisted audit techniques?", *Advances in Accounting*, **30(1)**:67-74;
- Byrnes P. E. (2015) "Developing Automated Applications for Clustering and Outlier Detection: Data Mining Implications for Auditing Practice" *Doctoral dissertation, Rutgers, The State University of New Jersey, Newark*;

- Blum R. L., (1983) "Representation of Empirically Derived Causal Relationships" *Proceedings of the International Joint Conference on Artificial Intelligence*, 268–271;
- Bogdanova S.V., Kozel I.V., Ermolina L.V., Litvinova T.N. (2016) "Management of Small Innovational Enterprise under the Conditions of Global Competition: Possibilities and Threats" *European Research Studies Journal*, **19(2)**:268–275;
- Bradford M., Henderson D., Baxter R.J., Navarro P., (2020) "Using generalized audit software to detect material misstatements, control deficiencies and fraud: How financial and IT auditors net audit benefits", *Managerial Auditing Journal*, **35**:521-547;
- Brazel J.F., Agoglia C.P., Hatfield R.C. (2004), "Electronic versus face-to-face review: the effects of alternative forms of review on auditors' performance", *The Accounting Review*, **79(4)**:949-966;
- Brazel J.F., Carpenter T.D., Jenkins J.G. (2010), "Auditors' use of brainstorming in the consideration of fraud: reports from the field", *The Accounting Review*, **85(4)**:1273-1301;
- Breiman L., Friedman J., Stone C. J., Olshen R. A. (1984) "Classification and regression trees." *CRC press*;
- Brown-Liburud H., Issa H., Lombardi D., (2015) "Behavioral implications of big data's impact on audit judgment and decision making and future research directions", *Accounting Horizons*, **29**:451-468;
- Brown R.G. (1962), "Changing audit objectives and techniques", *The Accounting Review*, **37-4**:696-703;
- Brown B., Chui M., Manyika J. (2011) "Are you ready for the era of "Big Data?"" *McKinsey Quarterly*, October: 24–35;
- Brown S., Tucker, J. (2011), "Large-sample evidence on firms' year-over-year MD&A modifications", *Journal of Accounting Research*, Vol. 49 No. 2, pp. 309-346;
- Bughin J., Livingston J., Marwaha S. (2011) "Seizing the potential of "Big Data." " *McKinsey Quarterly*, October: 103–109;
- Byrnes P.E., (2019) "Automated clustering for data analytics", *Journal of Emerging Technologies in Accounting*, **16**:43-58;
- Cao M., Chychyla R., Stewart T., (2015), "Big data analytics in financial statement audits", *Accounting Horizons*, **29**:423-429;

- Cardinaels E. (2008) "The interplay between cost accounting knowledge and presentation formats in cost-based decision-making" *Accounting, Organizations and Society*; **33(6)**:582–602;
- Casey, C. J. Jr. (1980) "Variation in accounting information load: The effect on loan officers' prediction of bankruptcy" *The Accounting Review*, January:36–49;
- Cecchini M., Aytug H., Koehler G. J., Pathak P., (2010), "Detecting Management Fraud in Public Companies", *Management Science*, **56**:1146-1160;
- Center for Audit Quality (CAQ) (2008) "Practice aid for testing journal entries and other adjustments pursuant to AU Section 316" Washington, DC: AICPA;
- Chartered Global Management Accountant (CGMA 2014). "CGMA briefing Big Data: Readyng business for the Big Data revolution";
- Clopton J., Heitger L.E., Morrow L. (2014) "Adding 'augmented intelligence' and 'datamining' to themix" *Fraud Magazine*; November/December;
- Coakley J. R., C. E. Brown (1993) "Artificial neural networks applied to ratio analysis in the analytical review process" *Intelligent Systems in Accounting, Finance and Management* **2 (1)**: 19–39;
- Cockrell C., Stone D.N. (2011), "Team discourse explains media richness and anonymity effects in audit fraud cue brainstorming", *International Journal of Accounting Information Systems*, **12(3)**:225-242;
- Comunale C.L., Rosner R.L., Sexton T.R., (2010), "The auditor's assessment of fraud risk: a fuzzy logic approach" *Journal of Forensic and Investigative Accounting* **3**:149–194;
- Conn, J. (2013) "Pairing up" *Modern Healthcare* **43(24)**: 8–9;
- Crumbley L., Heitger Smith L. S. (2015), "Commerce Clearing House, Chicago" *Forensic and Investigative Accounting*, 7th ed.;
- Cukier K., Mayer-Schoenberger V., (2013) "The rise of Big Data: How it's changing the way we think about the world" *Foreign Affairs*;
- Curtis M. B., Payne E. A. (2014), "Modeling voluntary CAAT utilization decision in auditing" *Managerial Auditing Journal*, **29(4)**:304—326;
- Curtis, E., Turley, S., (2007) "The Business Risk Audit: a longitudinal case study of an audit engagement" *Accounting, Organizations and Society*, **32 (4-5)**: 439–461;
- Dagilienė L., Klovienė L., (2019), "Motivation to use big data and big data analytics in external auditing" *Managerial Auditing Journal*, **34**:750-782;

- Dai J., Li Q., (2016), "Designing audit apps for armchair auditors to analyze government procurement contracts", *Journal of Emerging Technologies in Accounting*, **13**:71-88;
- Daroca F. P., Holder W. W. (1985) "The use of analytical procedures in review and audit engagements" *Auditing-A Journal of Practice & Theory*, **4(2)**: 80-92;
- Dastjerdi A.R., Foroghi D., Kiani G.H., (2019), "Detecting manager's fraud risk using text analysis: evidence from Iran", *Journal of Applied Accounting Research*, **20**:154-171;
- Davis A., Piger J., Sedor L. (2012), "Beyond the numbers: measuring the information content of earnings press release language", *Contemporary Accounting Research*, **29(3)**:845-868;
- Debreceeny R.S., Gray G.L., (2010) "Data mining journal entries for fraud detection: an exploratory study" *International Journal of Accounting Information Systems*, **11**:157-181;
- Debreceeny RS, Gray GL. (2014) "A taxonomy to guide research on the application of data mining to fraud detection in financial statement audits" Northridge: University of Hawaii and California State University;
- Dechow P. M., Ge W., Larson C. R., Sloan R. G., (2011), "Predicting Material Accounting Misstatements", *Contemporary Accounting Research*, **28**:17-82;
- Deloitte (2011) "Visual analytics: revealing corruption, fraud, waste, and abuse";
- Deloitte (2012). "The insight economy: Big Data matters – Except when it doesn't" New York, NY: Deloitte;
- Dennehy, B. (2016) "How to use Big Data to create business advantage in the real world. Washington society of certified public accountants annual meeting" Seattle, WA;
- Dennis A.R., Valacich J.S. (1993), "Computer brainstorming: more heads are better than one", *The Journal of Applied Psychology*, **78-4**:531-537;
- Didimo W., Liotta G. (2006), "Graph visualization and data mining", *Mining Graph Data*, 35-63;
- Di Giacomo E., Didimo W., Liotta G., Palladino P. (2010), "Visual analysis of financial crimes:[system paper]", *Proceedings of the International Conference on Advanced Visual Interfaces*, ACM, 393-394;



- Dilla W, Janvrin D, Raschke R. (2010) "Interactive data visualization: new directions for accounting information systems research" *Information Systems* **24(2)**:1-37;
- Dilla W.N., Raschke R.L., (2015), "Data visualization for fraud detection: Practice implications and a call for future research", *International Journal of Accounting Information Systems*, **16**:1-22;
- Dyck A., Morse A., L. Zingales. (2010) "Who Blows the Whistle on Corporate Fraud?" *Journal of Finance* **LXV (6)**:2213-2253;
- Dong W., Liao S., Zhang Z., (2018), "Leveraging Financial Social Media Data for Corporate Fraud Detection", *Journal of Management Information Systems*, **35**:461-484;
- Dorsch, J.J., Yasin, M.Y., (1998) "A framework for benchmarking in the public sector: literature review and directions for future research" *International Journal of Public Sector Management* **11 (2/3)**: 91-115;
- Dowling, C., Leech S. (2007 ) "Audit support systems and decision aids: Current practice and opportunities for future research" *International Journal of Accounting Information Systems* **8 (2)**: 92-116;
- Dumay J., Garanina T., (2013), "Intellectual capital research: a critical examination of the third stage", *Journal of Intellectual Capital*, **14**:10-25;
- Earley C.E., (2015), "Data analytics in auditing: Opportunities and challenges", *Business Horizons*, **58**:493-500;
- Eining, M. M., Jones D. R., Loebbecke J. K. (1997) "Reliance on decision aids: An examination of auditors' assessment of management fraud" *Auditing: A Journal of Practice & Theory* **16 (2)**: 1-19;
- Elliott, R.K., (1992) "The third wave breaks on the shores of accounting" *Account. Horizont* **6 (2)**:61-85;
- Enget K., Saucedo G.D., Wright N.S., (2017), " Mystery, Inc.: A Big Data case", *Journal of Accounting Education*, **38**:9-22;
- Erickson, M., Hanlon M., Maydew E. L. (2006) "Is There a Link between Executive Equity Incentives and Accounting Fraud?" *Journal of Accounting Research* **44**:113-143;
- Ernst & Young. (2010) "Driving ethical growth—New markets, new challenges." 11th Global Fraud Survey;

- Fay R., Negangard E.M., (2017), "Manual journal entry testing: Data analytics and the risk of fraud", *Journal of Accounting Education*, **38**:37-49;
- Fawcett, T. "An Introduction to Roc Analysis." (2006) *Pattern Recognition Letters* **27**: 861-874;
- Few S. (2007) "Data visualization past, present, and future" *Perceptual edge whitepaper*;
- Fjermestad J., Hiltz S.R. (1998), "An assessment of group support systems experiment research: methodology and results", *Journal of Management Information Systems*, **15(3)**:7-149;
- Free C., Murphy P. R. (2015). "The ties that bind: The decision to co-offend in fraud" *Contemporary Accounting Research*, **32(1)**:18-54;
- Gale W.A., Pregibon D. (1982) "An Expert System for Regression Analysis" *Proceedings of 14th Symposium on Interface of Computers and Statistics*, 110-117;
- Gepp A., Linnenluecke M.K., O'Neill T.J., Smith T., (2018), "Big data techniques in auditing research and practice: Current trends and future opportunities", *Journal of Accounting Literature*, **40**:102-115;
- Gleason C., Jenkins N. T., Johnson W. B. (2008) "The Contagion Effects of Accounting Restatements." *The Accounting Review* **83**: 83-110;
- Goel S., Gangolly J., (2012) "Beyond the numbers: mining the annual reports for hidden cues indicative of financial statement fraud" *Intelligent Systems in Accounting, Finance and Management* **19**:75–89;
- Goel S., Gangolly J., Faerman S.R., Uzuner O., (2010) "Can linguistic predictors detect fraudulent financial filings?" *Journal of Emerging Technologies in Accounting* **7**:25–46;
- Goldman E., Peyer U., Stefanescu I. (2012) "Financial Misrepresentation and Its Impact on Rivals." *Financial Management* **41**: 915-945;
- Gray G. L., Debreceeny R. S. (2013) "A Taxonomy to Guide Research on the Application of Data Mining to Fraud Detection in Financial Statement Audits" *Working paper, California State University, Northridge*;
- Gray G.L., Debreceeny R.S., (2014) "A taxonomy to guide research on the application of data mining to fraud detection in financial statement audits" *International Journal of Accounting Information Systems* **15**:357–380;

- Granlund M., (2011) "Extending AIS research to management accounting and control issues: a research note" *International Journal Accounting Information System* **12** (1): 3-19;
- Greene, C.L. (2003a), "Audit those vendors", *The White Paper, McGovern & Greene*;
- Guan J., Levitan A.S., Goyal S., (2018), "Text mining using latent semantic analysis: An illustration through examination of 30 years of research at JIS", *Journal of Information Systems*, **32**:67-86;
- Gupta, R., Gill, N.S., (2012a) "Financial statement fraud detection using text mining" *International Journal of Advanced Computer Science and Application* **3**;
- Guthrie J., Ricceri F., Dumayc J., (2012), "Reflections and projections: A decade of Intellectual Capital Accounting research", *The British Accounting Review*, **44**:68-82;
- Freund Y., Schapire R. (1997) "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting." *Journal of Computer and System Sciences* **55**: 119 – 139;
- Han D., (2017), "Researches of detection of fraudulent financial statements based on data mining", *Journal of Computational and Theoretical Nanoscience*, **14**:463-469;
- He, H., Ma Y. (2013) "Imbalanced Learning: Foundations, Algorithms, and Applications." *Wiley*;
- Herbig P. A., Kramer H. (1994) "The effect of information overload on the innovation choice process: Innovation overload" *Journal of Consumer Marketing* **11**: 45-54;
- Hoffman W., (2008) "Fighting supply-chain fraud" *Traffic World*;
- Hogan C. E., Rezaee Z., Riley R. A., Velury U. K. (2008) "Financial statement fraud: Insights from the academic literature" *Auditing: A Journal of Practice & Theory*, **27(2)**:231-252;
- Holton, C. (2009) "Identifying disgruntled employee systems fraud risk through text mining: A simple solution for a multi-billion dollar problem" *Decision Support Systems* **46**: 853-864;
- Huerta E., Jensen S., (2017), "An accounting information systems perspective on data analytics and big data", *Journal of Information Systems*, **31**:101-114;

- Hung M., Wong T. J., Zhang F. (2015) "The Value of Political Ties versus Market Credibility: Evidence from Corporate Scandals in China." *Contemporary Accounting Research*, **32(4)**:1641-1675;
- Hughes, P. (2013) "Making waves" *Best's Review* **114(4)**: 44;
- Humpherys S. L., Moffitt K. C, Burns M. B., Burgoon J. K., Felix W. F.. (2011) "Identification of fraudulent financial statements using linguistic credibility analysis" *Decision Support Systems* **50 (3)**: 585–594;
- Hung M., Wong T.J., Zhang F. (2015), "The value of political ties versus market credibility:evidence from corporate scandals in China", *Contemporary Accounting Research*, **32**:1641-1675;
- Issa H., Kogan A. (2014) "A predictive ordered logistic regression model as a tool for quality review of control risk assessments" *Journal of Information Systems* **28**: 209–229;
- Jacoby J. (1977) "Information load and decision quality: Some contested issues" *Journal of Marketing Research* 569–573;
- Jacoby J. (1984) "Perspectives on information overload" *Journal of Consumer Research*: 432–435;
- Jans M., Lybaert N., Vanhoof K., (2010) "Internal fraud risk reduction: results of a data mining case study" *International Journal of Accounting Information Systems* **11**:17–41;
- Jans M., van der Werf J.M., Lybaert N., Vanhoof K., (2011) "A business process mining application for internal transaction fraud mitigation" *Expert Systems Applications* **38**:13351–13359;
- Jedrzejek C., Bak J., Falkowski M. (2009) "Graph Mining for Detection of a Large Class of Financial Crimes" *In 17th International Conference on Conceptual Structures, Moscow*, 26-31;
- Kaminski K.A.; Wetzel T.S.; Guan L. (2004) "Can financial ratios detect fraudulent financial reporting?" *Managerial Auditing Journal*, **19(1)**:15–28;
- Karpoff J.M., Koester A., Lee D. S., Martin G. S.. (2017) "Proxies and databases in financial misconduct research." *The Accounting Review* **92**: 129–163;
- Khrestina M.P., Dorofeev D.I., Kachurina P.A., Usubaliev T.R., Dobrotvorskiy A.S., (2017), "Development of algorithms for searching, analyzing and detecting

- fraudulent activities in the financial sphere”, *European Research Studies Journal*, **20**:484-498;
- Kim Y., Vasarhelyi M.A. (2012), “A model to detect potentially fraudulent/abnormal wires of an insurance company: an unsupervised rule-based approach”, *Journal of Emerging Technologies in Accounting*, **9(1)**:95-110;
  - King, W. B. (2013) “How CUs can use Big Data to drive big revenue” *Credit Union Journal* 17:24;
  - Kirkos E., Spathis C., Manolopoulos Y. (2007) “Data mining techniques for the detection of fraudulent financial statements” *Expert Systems with Applications*, **4**:995-1003;
  - Kochetova-kozloski N., Messier Jr. W.F., Eilifsen, A., (2011) “Improving auditors' fraud judgments using a frequency response mode” *Contemporary Accounting Research* **28**:837–858;
  - Koh H., Woo E.S. (1998), “The expectation gap in auditing”, *Managerial Auditing Journal*, **13-3**:147-154;
  - Koh C., Low K. (2004) “Going concern prediction using data mining techniques” *Managerial Auditing Journal* **3**:462-476;
  - Kraus C., Valverde R., (2014), “A data warehouse design for the detection of fraud in the supply chain by using the benford's law”, *American Journal of Applied Sciences*, **11**:1507-1518;
  - Larcker D., Zakolyukina A. A. (2012) “Detecting Deceptive Discussion in Conference Calls.” *Journal of Accounting Research* **50**: 495-540;
  - La Torre, Botes, Dumay, Odendaal, (2019), “Protecting a new Achilles heel: the role of auditors within the practice of data protection”, *Managerial Auditing Journal* (article non pubblicato);
  - La Torre M., Dumay J., Rea M.A. (2018), “Breaching intellectual capital: critical reflections on big data security”, *Meditari Accountancy Research*, **26**:463-482;
  - Lanza R. (2005b) “Fraud fighting with data analysis” *Fraud Magazine*;
  - Lanza R. (2006) “Proactive journal entry testing: Detecting entries made in themiddle of the night” *Fraud Magazine*;
  - Lanza R.B. (2007), “Auditing vendor accounts for fraud or at least some cash recovery”, *Fraud Magazine* ACFE, Austin;

- Lanza R, Gilbert S. (2007) "A risk-based approach to journal entry testing" *Journal Accounting* **204(1)**:32-5;
- Larcker D. Zakolyukina A. A. (2012) "*Detecting Deceptive Discussion in Conference Calls*", *Journal of Accounting Research* **50**:495-540;
- Lee, D. (2016) "KPMG recruits IBM Watson for cognitive tech audits, insights" *Accounting Today*;
- Li, F. (2008), "Annual report readability, current earnings, and earnings persistence", *Journal of Accounting and Economics*, **45 (2/3)**:221-247;
- Li, F. (2010), "Textual analysis of corporate disclosures: a survey of the literature", *Accounting Literature*, **29(1)**:143-165;
- Libby, R. (1985) "Availability and the generation of hypotheses in analytical review" *Journal of Accounting Research* 648-667;
- Little A., Best P.J. (2003), "A framework for separation of duties in an SAP R/3 environment", *Managerial Auditing Journal*, **18(5)**: 419-430;
- Liu X.-Y., Zhou Z.-H. (2013) "Ensemble learning methods for Class Imbalance Learning." *Imbalanced Learning: Foundations, Algorithms, and Applications*, John Wiley & Sons, Inc.;
- Lynch A.L., Murthy U.S., Engle T.J. (2009), "Fraud brainstorming using computer mediated communication: the effects of brainstorming technique and facilitation", *The Accounting Review*, **84-4**:1209-1232;
- Lombardi D. R. (2012) "Using an Expert System to Debias Auditor Judgment: An Experimental Study" *Dissertation, Rutgers, The State University of New Jersey*;
- Loughran T., McDonald B. (2011), "When is a liability not a liability? Textual analysis, dictionaries, and 10-Ks", *Journal of Finance* **66(1)**:35-65;
- Lurie N, Mason C. (2009), "Visual representation: implications for decision making." *Journal Mark* **71(1)**:160-77;
- Mayne M., (2010) "Elementary, my dear Watson? For IT Security Professionals" *SC Magazine*;
- Malhotra N. K. (1982) "Information load and consumer decision making" *Journal of Consumer Research* 419-430;
- Martin M. (2013) "Big Data/social media combo poised to advance healthcare" *HPC Source* (April): 33-35;

- Massaro M., Dumay J., Guthrie J. (2016), "On the shoulders of giants: undertaking a structured literature review in accounting", *Accounting, Auditing & Accountability Journal*, **26**:767-801;
- Matthews D. (2006) "A History of Auditing, Taylor and Francis" New York, NY;
- McGinty J. C. (2014) "Accountants increasingly use data analysis to catch fraud: Auditors wield mathematical weapons to detect cheating" *Wall Street Journal*;
- McKinsey Global Institute (2011) "Big Data: The next frontier for innovation, competition, and productivity" *mckinsey digital*;
- Moll J., Yigitbasioglu O., (2019), "The role of internet-related technologies in shaping the work of accountants: New directions for accounting research", *British Accounting Review*, **51**:1-16;
- Mosteanu N.R., Faccia A., (2020), "Digital systems and new challenges of financial management – fintech, XBRL, blockchain and cryptocurrencies", *Quality - Access to Success*, **21**:159-166;
- Myers, M. (2013) "Credit screening and analysis tools extend to collections: Searching for peaches among unmarked cans" *Business Credit* **115**: 32–34;
- Murphy, K. J. (1999) "Executive compensation." *Handbook of Labor Economics* **3**: 2485-2563;
- Murphy. M. L. (2014) "How to prepare for auditing in a digital world of Big Data" *Journal of Accountancy*;
- Nigrini, M. J. (1999) "I've got your number: How a mathematical phenomenon can help CPAs uncover fraud and other irregularities" *Journal of Accountancy*;
- No W.G., Lee K., Huang F., Li Q., (2019), "Multidimensional audit data selection (MADS): A framework for using data analytics in the audit data selection process", *Accounting Horizons*, **33**:127-140;
- Norris F., (2011) "Troubled Audit Opinions" N.Y. Times June 10;
- O' Donnell E., Perkins J. D. (2011) "Assessing risk with analytical procedures: Do systems-thinking tools help auditors focus on diagnostic patterns?" *Auditing: A Journal of Practice & Theory* **30 (4)**: 273–282;
- O'Gara J.D. (2004), "Corporate Fraud Case Studies in Detection and Prevention", Wiley;
- O'Leary D.E. (2018) "Big Data and Knowledge Management with Applications in Accounting and Auditing: The Case of Watson" *SSRN Electronic Journal*;

- Owusu-Ansah S., Moyes G.D., Oyelere P.B., Hay D., (2002) "An empirical analysis of the likelihood of detecting fraud in New Zealand" *Management Audit Journal* **17**:192–204;
- Özera G., Babacanb B., (2013) "Benford's Law and Digital Analysis: Application on Turkish Banking Sector" *Business Economic Research Journal*, **4**: 29-41;
- Pentland A. (2014) "With Big Data comes big responsibility" *Harvard Business Review*;
- Petty R., Guthrie J. (2000), "Intellectual capital literature review measurement, reporting and management", *Journal of Intellectual Capital*, **1**:155-176;
- Pincus K. V. (1989) "The efficacy of a red flags questionnaire for assessing the possibility of fraud" *Accounting, Organizations and Society* **14 (1)**: 153–163;
- Public Company Accounting Oversight Board (PCAOB) (2016b) "Identifying and assessing risks of material misstatement" Auditing Standards (AS) 2110, Washington;
- Purda L.; Skillicorn D. (2014) "Accounting variables, deception, and a bag of words: Assessing the tools of fraud detection" *Contemporary Accounting Research*, **32 (3)**:1193–1223;
- Ramlukan, R. (2015), "How big data and analytics are transforming the audit" *Financial Executives International Daily*;
- Ransbotham S., Kiron D., Prentice P. K. (2015) "Minding the analytics gap" *MIT Sloan Management Review* **56 (3)**: 63–68;
- Rasinski T.V., Padak N., Newton J., Newton E. (2011), "The Latin–Greek connection", *The Reading Teacher*, **65-(2)**:133-141;
- Rezaee Z., Larry Crumbley D., Elmore R.C. (2004), "Forensic accounting education: a survey of academicians and practitioners", *Advances in Accounting Education*, **6**:193-231;
- Rezaee Z., Lo D., Ha M., Suen A. (2016), "Forensic accounting education and practice: insights from China", *Journal of Investigative and Forensic Accounting*, **8**:106-119;
- Rezaee Z., Wang J., (2019), "Relevance of big data to forensic accounting practice and education", *Managerial Auditing Journal*, **34**:268-288;



- Richards R., Stevens R., Silver L., Metts, S. (2019) "Overcoming employer perceptions of online accounting education with knowledge" *Administrative Issues Journal: Connecting Education, Practice, and Research*, **8(2)**:70-80;
- Rose A.M., Rose J.M., Sanderson K.A, Thibodeau J.C., (2017), "When should audit firms introduce analyses of big data into the audit process?", *Journal of Information Systems*, **31**:81-99;
- Russom, P. (2011) "Big Data analytics" *TDWI Best Practices Report* (Fourth Quarter);
- Salijeni G., Samsonova-Taddei A., Turley S., (2019), "Big Data and changes in audit technology: contemplating a research agenda", *Accounting and Business Research*, **49**:95-119;
- Scharff M. (2005) "Understanding WorldCom's accounting fraud: Did groupthink play a role?" *Journal of Leadership & Organizational Studies*, **11(3)**:109-118;
- Schmarzo, W. D. (2013) "Big Data: Understanding How Data Powers Big Business" *Indianapolis, IN: Wiley*;
- Schneider S. C. (1987) "Information overload: Causes and consequences" *Human Systems Management* **7**:143-153;
- Seiffert C., Khoshgoftaar T. M., Van Hulse J., Napolitano A. (2010) "Rusboost: A Hybrid Approach to Alleviating Class Imbalance." *IEEE Transactions on Systems Man and Cybernetics Part a-Systems and Humans* **40**: 185-197;
- Selby D. (2011) "Can financial statement auditors identify risk patterns in IT control evidence?" *International Journal of Business, Humanities and Technology* **1** (3);
- Singh K., Best P., (2016), "Interactive visual analysis of anomalous accounts payable transactions in SAP enterprise systems", *Managerial Auditing Journal*, **31**:35-63;
- Singleton T., Singleton A., Bologna J., Lindquist R. (2008), "Fraud Auditing and Forensic Accounting" John Wiley & Sons;
- Smith A.L., Murthy U.S., Engle T.J. (2012), "Why computer-mediated communication improves the effectiveness of fraud brainstorming", *International Journal of Accounting Information Systems*, **13(4)**:334-356;
- Solis B., Littleton A. (2017) "The 2017 State of Digital Transformation" *Research Report*. Altimeter Group;

- Sparrow P. (1999) "Strategy and cognition: Understanding the role of management knowledge structures, organizational memory, and information overload" *Creativity and Innovation Management* **8**:140–148;
- Stroeveva O.A., Mironenko N.V., Lyapina I.R., Petrukhina E.V. (2016) "Peculiarities of Formation of Socially Oriented Strategy of Economic Growth of National Economy" *European Research Studies Journal*, **19(2)**:161-170;
- Summers S. L., Sweeney J. T. (1998) "Fraudulently Misstated Financial Statements and Insider Trading: An Empirical Analysis." *The Accounting Review* **73**:131-146;
- Sun Y., Vasarhelyi M.A., (2018), "Embracing textual data analytics in auditing with deep learning" *International Journal of Digital Accounting Research*, **18**:49-67;
- Tackett J.A., (2013) "Association rules for fraud detection" *Journal of Corporate Accounting and Finance* **24**:15–22;
- Tang J., Karim K.E., (2019), "Financial fraud detection and big data analytics – implications on auditors' use of fraud brainstorming session", *Managerial Auditing Journal*, **34**:324-337;
- Thalassinos I.E., Maditinos D., Paschalidis A. (2012) "Observing evidence of insider trading in the Athens Stock Exchange" *Journal of Economic Structures*, **1(1)**:1-15;
- Thiprungsri S., Vasarhelyi M. A. (2011) "Cluster analysis for anomaly detection in accounting data: An audit approach" *The International Journal of Digital Accounting Research* **11 (17)**: 69–84;
- Tiberius V., Hirth S., (2019), "Impacts of digitization on auditing: A Delphi study for Germany", *Journal of International Accounting, Auditing and Taxation*, **37**:1-14;
- Tödter K.H., (2009) "Benford's law as an indicator of fraud in economics" *German Economic Review*, **10**: 339- 351;
- Tory M., Moller T. (2004), "Human factors in visualization research", *IEEE Transactions on Visualization and Computer Graphics*, **10(1)**:1-13;
- Torpey D., Walden V., M. Sherrod (2009) "Fraud triangle analytics" *Fraud Magazine*;

- Valacich J.S., Dennis A.R., Connolly T. (1994), "Idea generation in computer-based groups: a new ending to an old story", *Organizational Behavior and Human Decision Processes*, **57-3**:448-467;
- Van Peurseem K., Pratt M., Cordery, C. (2011), *Auditing*, Pearson;
- Vasarhelyi M. A., Halper F. B. (1991) "The continuous audit of online systems" *Auditing: A Journal of Practice & Theory* **10 (1)**:110–125;
- Vovchenko G.N., Tishchenko N.E., Epifanova V.T., Gontmacher B.M. (2017) "Electronic Currency: The Potential Risks to National Security and Methods to Minimize Them" *European Research Studies Journal*, **20(1)**:36-48;
- Wakunuma K.J., Stahl B.C. (2014), "Tomorrow's ethics and today's response: an investigation into the ways information systems professionals perceive and address emerging ethical issues", *Information Systems Frontiers*, **16-3**:383-397;
- Wang T., Cuthbertson R., (2015), "Eight issues on audit data analytics we would like researched", *Journal of Information Systems*, **29**:155-162;
- Warren J.D., Moffitt K.C., Byrnes P., (2015), "How big data will change accounting", *Accounting Horizons*, **29**:397-407;
- Wells JT. (2003) "Sherlock Homes, CPA Part 1" *Journal Account*; **196(2)**:86–90;
- Wells J.T. (2011), "Principles of Fraud Examination, 3rd ed." John Wiley & Sons;
- Wu X., Kumar V., Quinlan J. R., Ghosh J., Yang Q., Motoda H., Steinberg D. (2008) "Top 10 algorithms in data mining." *Knowledge and Information Systems*, 1-37;
- Yoon K., Hoogduin L., Zhang L., (2015), "Big data as complementary audit evidence", *Accounting Horizons*, **29**:431-438;
- Yu Z., Guang Y., Zi-qi J., (2013) "Violations detection of listed companies based on decision tree and K-nearest neighbor" *Proceeding of the International IEEE Conference on Management Science and Engineering (ICMSE), Harbin, China* 1671–1676;
- Yigitbasioglu OM, Velcu O. (2012) "A review of dashboards in performance management: implications for design and research" *International Journal of Accounting Information Systems*; **13(1)**:41–59;
- Zhao N., Yen D.C., Chang I.-C. (2004), "Auditing in the e-commerce era", *Information Management and Computer Security*, **12-5**:389-400.

## SITOGRAFIA

- Best J. (2016) "IBM Watson: The inside story of how the Jeopardy-winning supercomputer was born, and what it wants to do next. Tech Republic." <http://www.techrepublic.com/article/ibm-watson-the-inside-story-of-how-thejeopardy-winning-supercomputer-was-born-and-what-it-wantsto-do-next/>;
- BigData4Innovation (2020) "Big Data: Cosa sono, come utilizzarli, soluzioni ed esempi applicativi" <https://www.bigdata4innovation.it/big-data/big-data-analytics-data-science-e-data-scientist-soluzioni-e-skill-della-data-driven-economy/>;
- Bochkay K., Levine C. (2013) "Using MD&A to improve earnings forecasts" [http://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=2253054](http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2253054);
- Claburn, T. (2016) "IBM Watson: Machine-of-all-trades, Information Week" May 16. <http://www.informationweek.com/big-data/big-dataanalytics/ibm-watson-machine-of-all-trades/d/d-id/1325483>;
- Data, data everywhere (2010), "The Economist" February 25. <http://www.economist.com/node/15557443>;
- Ernst and Young (EY) (2016), "Global forensic data analytics survey 2016" [www.ey.com/gl/en/services/assurance/fraud-investigation-dispute-services/eyshifting-into-high-gearmitigating-risks-and-demonstrating-returns](http://www.ey.com/gl/en/services/assurance/fraud-investigation-dispute-services/eyshifting-into-high-gearmitigating-risks-and-demonstrating-returns);
- ERP: <https://www.oracle.com/it/applications/erp/what-is-erp.html>;
- Ferroni E. (2016) <https://forward.recentiproggressi.it/it/rivista/numero-4-big-data/articoli/una-nuova-sfida-per-l-epidemiologia/>;
- Forbes "\$16.1 Billion Big Data Market: 2014 Predictions From IDC and IIA" [www.forbes.com/sites/gilpress/2013/12/12/16-1-billion-big-data-market-2014-predictions-from-idc-and-ia/#3f285f304482](http://www.forbes.com/sites/gilpress/2013/12/12/16-1-billion-big-data-market-2014-predictions-from-idc-and-ia/#3f285f304482);
- IDC: <https://www.idcitalia.com/chi-e-idc>;
- La revisione legale (2017) "Le frodi e la revisione legale del bilancio" <https://www.larevisionelegale.it/2017/06/09/le-frodi-la-revisione-legale-del-bilancio/>;
- Il sole 24 ore (2019) "Commercialisti con l'arma in più dei big data" <https://www.ilsole24ore.com/art/commercialisti-l-arma-piu-big-data-ACQCizb>;
- Markets, Markets (2017), "Big data market worth 66.79 billion USD by 2021" [www.marketsandmarkets.com/PressReleases/big-data.asp](http://www.marketsandmarkets.com/PressReleases/big-data.asp);

- PCAOB “Standing Advisory Group”  
<https://pcaobus.org/Standards/SAG/Pages/default.aspx>;
- Types of Analytics: descriptive, predictive, prescriptive analytics  
<https://www.dezyre.com/article/types-of-analytics-descriptive-predictive-prescriptive-analytics/209>;
- Unicusano “Cos’è il falso in bilancio? Definizione, Storia e Normativa”  
<https://www.unicusano.it/blog/didattica/master/falso-in-bilancio/>;
- Un plus (2017) “Big Data, big impact on accounting”  
<https://aplusmag.goodbarber.app/topics/c/0/i/17867251/big-data-big-impact-accounting>.