

*preprint di capitolo in
E. Melloni, G. Vecchi (ed.)
PNRR, giustizia e ufficio per il processo: Risultati di una collaborazione
tra uffici giudiziari e università
Franco Angeli, 2024*

8 Valorizzare i dati degli uffici giudiziari: per un cruscotto previsionale

di Barbara Pernici e Marco Dilettis

8.1 Introduzione

La performance del sistema giudiziario è una delle questioni rilevanti emerse nell'ultimo decennio nel campo delle riforme del settore pubblico. Diverse ragioni spiegano questo interesse, che è andato oltre le specifiche discipline giuridiche per coinvolgere gli studi di politica pubblica, management, economia e tecnologie della comunicazione - ICT.

Il sistema giudiziario rappresenta uno dei pilastri dei regimi democratici: da un lato, il suo buon funzionamento influenza il rispetto dei diritti umani e civili e dall'altro ha un impatto sullo sviluppo economico nazionale e territoriale. La performance della magistratura è entrata nell'agenda istituzionale e accademica in Europa con l'obiettivo di introdurre pratiche e strumenti di gestione nei tribunali e nelle organizzazioni giudiziarie, seguendo (con un certo ritardo) le riforme e i modelli che hanno caratterizzato il settore pubblico degli ultimi due decenni del secolo scorso e, più recentemente, innescati dallo sviluppo delle ICT. Il tema della performance giudiziaria occupa un posto di primo piano nell'agenda delle riforme del settore pubblico italiano. Infatti, la magistratura italiana presenta, rispetto agli altri Stati membri dell'UE, una delle posizioni peggiori per quanto riguarda la durata delle cause civili e commerciali; nonostante alcuni programmi di riforma dell'ultimo decennio, secondo i rapporti CEPEJ, l'Italia rimane nella zona bassa della classifica europea per quanto riguarda l'indicatore *disposition time* (la misura del tempo necessario per decidere tutto l'arretrato di cause pendenti, mantenendo l'attuale livello di produttività organizzativa).

Nel presente lavoro si studiano le caratteristiche dei processi per quanto riguarda la loro esecuzione in termini di fasi e eventi relativi al processo.

L'obiettivo è quello di ottenere le basi per sviluppare un cruscotto di monitoraggio dei processi di tipo predittivo, in cui si visualizzi non solo l'andamento corrente dei processi, ma si possa avere una stima dei tempi attesi, che consenta di monitorare quei processi che potrebbero raggiungere tempi di durata di tipo critico. Oltre allo studio teorico, l'analisi è stata applicata a un dataset di dati storici della CdA di Milano e si è studiata la precisione dei risultati ottenuti.

Nel presente capitolo si presenta inizialmente nel paragrafo 8.2 lo stato dell'arte riguardante l'analisi di processi in generale anche con tecniche di intelligenza artificiale. Successivamente nel paragrafo 8.3 si illustrano le caratteristiche dei dati disponibili e si illustrano i modelli di analisi e predittivi sviluppati nella ricerca. Vengono infine presentati e discussi i risultati ottenuti nel paragrafo 8.4.

8.2 Stato dell'arte

Le tecniche di *process mining* consentono di analizzare i processi a partire dai log di registrazione degli eventi, attraverso le fasi di estrazione dei dati, preparazione dei dati, la costruzione automatica di modelli dei processi, controllo di conformità e del rispetto dei vincoli, e analisi delle prestazioni. Le tecniche di *process mining* e data mining sono state studiate in lavori recenti, non solo per analizzare il comportamento globale dei processi, ma anche per individuare anomalie e situazioni critiche. Recentemente, il *process mining* è stato potenziato da tecniche ispirate all'intelligenza artificiale, per l'analisi delle eccezioni, la predizione della durata dei processi e dei tempi di attesa, la classificazione di diversi tipi di cause di ritardo come il *batching* o contesa delle risorse. Il *process mining* è stato applicato ai sistemi giudiziari nei tribunali brasiliani per derivare mappe di processo che vengono utilizzate per identificare rallentamenti e colli di bottiglia e di analizzare i tempi dei processi sulla base di diverse dimensioni di analisi, ad esempio, confrontando i processi cartacei e digitali. Recentemente, tecniche di *deep learning* sono state applicate per prevedere la durata di una fase. Nel nostro lavoro precedente (PERNICI et al. 2024) abbiamo iniziato a discutere le direzioni per analizzare non solo sequenze di eventi, ma anche quali stati ed eventi influenzano sulla durata dei processi. In questo capitolo sviluppiamo ulteriormente le nostre idee iniziali e proponiamo un nuovo approccio per analizzare l'andamento dei processi e per prevederne la durata.

8.3 Modelli dei processi

Nel presente lavoro i processi vengono analizzati a partire dai dati disponibili nel SICID (sistema informatico contenzioso civile distrettuale) che consente di registrare gli eventi relativi ai processi in corso nel settore civile e informazioni generali relative ai processi. In questa sezione si illustrano le principali caratteristiche di queste registrazioni e si mostra come possano essere utilizzate per analizzare l'andamento dei processi. Si discutono infine tecniche per la creazione di modelli previsionali sulla durata dei processi basati sui dati disponibili nel sistema SICID.

8.3.1 *Stati e eventi dei processi*

Dal sistema SICID è possibile estrarre lo storico degli eventi utilizzando le informazioni dalle tabelle FASC, STOR, contenenti rispettivamente informazioni sui fascicoli e sullo storico degli eventi, e dalle tabelle di descrizione di stati e eventi. La TAB. 8.1 fornisce una descrizione delle informazioni disponibili: la registrazione si basa su un modello che definisce quali sono gli stati in cui si trova il processo prima e dopo un evento. Gli stati sono codificati con una sigla e da una descrizione standardizzata (ad esempio, AS, ATTESA ASSEGNAZIONE SEZIONE). In genere, la maggior parte degli stati sono stati denominati in base all'attesa di un evento conclusivo che li porti in un altro stato. Nell'esempio riportato, alla riga 5 l'evento 0F, DESIGNAZIONE GIUDICE E FISSAZIONE PRIMA UDIENZA fa passare il processo da uno stato GC ATTESA DI DESIGNAZIONE GIUDICE REL./COLLEGIO allo stato UT, ATTESA ESITO DI UDIENZA TRATTAZIONE (Art. 350). Per ogni evento vengono riportate una data corrispondente all'accadimento dell'evento e una data di registrazione dell'evento nel sistema (qui semplificata, nel sistema sono riportati anche ora e minuti di registrazione).

In generale, i dati raccolti dal sistema SICID hanno una buona qualità dei dati, sia in termini di accuratezza che di consistenza. Si osserva che alcuni attributi nelle relazioni sono fortemente incompleti e in tal caso sono stati esclusi dall'analisi presentata nel seguito. Si descrivono nel seguito le informazioni prese in esame nella ricerca.

TAB. 8.1 Registro storico degli eventi

NUM_RUOLO	CCODST Codice stato post- evento	CSTAPR Codice stato precedente	CDESCR Descrizione stato	CCDOEV Codice evento	DESCR_EV Descrizione evento	DATAEV Data Evento	DATAE Data registrazione
10/2018	AS		ATTESA ASSEGNAZIONE SEZIONE	IA	ISCRIZIONE RUOLO GENERALE	2018-01-02	2018-02-09
10/2018	AS	AS	ATTESA ASSEGNAZIONE SEZIONE	RP	RICHIESTA FASCICOLO PRIMO GRADO	2018-02-09	2018-02-09
10/2018	GC	AS	ATTESA DESIGNAZIONE GIUDICE REL./COLLEGIO	AS	ASSEGNAZIONE A SEZIONE	2018-02-16	2018-02-16
10/2018	GC	GC	ATTESA DESIGNAZIONE GIUDICE REL./COLLEGIO	W1	ALLEGATO FASCICOLO DI PRIMO GRADO	2018-02-16	2018-02-16
10/2018	UT	GC	ATTESA ESITO UDIENZA TRATTAZIONE (Art. 350)	OF	DESIGNAZIONE GIUDICE E FISSAZIONE PRIMA UDIENZA	2018-02-19	2018-02-19
10/2018	UT	UT	ATTESA ESITO UDIENZA TRATTAZIONE (Art. 350)	B2	ACQUISIZIONE FASCICOLO	2018-03-27	2018-03-27
10/2018	UT	UT	ATTESA ESITO UDIENZA TRATTAZIONE (Art. 350)	CP	COSTITUZIONE PARTI	2018-05-14	2018-05-14
10/2018	UT	UT	ATTESA ESITO UDIENZA TRATTAZIONE (Art. 350)	J1	DEPOSITO ATTO NON CODIFICATO	2018-06-12	2018-06-12
10/2018	PC	UT	ATTESA ESITO UDIENZA DI PRECISAZIONE CONCLUSIONI (Art. 352)	YB	RINVIO ALL'UDIENZA DI PRECISAZIONE CONCLUSIONI (art.352 cpc)	2018-06-14	2018-06-14

Fonte: propria elaborazione

8.3.2 Informazioni sui fascicoli

Oltre ai dati storici sugli eventi nei processi, il sistema SICID fornisce anche nella tabella FASC altre informazioni relative ai fascicoli (metadati). I metadati dei fascicoli presi in considerazione nello studio sono i seguenti:

- *Sezione*: Codice della sezione a cui viene assegnato il fascicolo, come riportata in FASC.
- *Codice oggetto*: valore numerico di 6 cifre che indica il ruolo (prima cifra), la materia (seconda e terza cifra) e infine l'oggetto del fascicolo, secondo la classificazione standardizzata prevista dal Ministero della Giustizia. Tale classificazione può presentare piccole varianti nel corso degli anni.
- *Numero di ruolo*: viene considerato il numero di iscrizione a ruolo, in formato numero/anno. A tale numero possono corrispondere anche più numeri progressivi dei procedimenti dei casi nello storico, che in tal caso sono stati raggruppati in un'unica sequenza riguardante l'intero fascicolo.

8.3.3 *Key performance indicators*

Nell'ambito della valutazione della durata dei procedimenti giudiziari, sono state utilizzate in questo lavoro tre soglie di riferimento significative: 'Obiettivo PNRR', 'Mediana della Corte' e 'Legge Pinto', fissate rispettivamente a 287, 472 e 730 giorni. Queste soglie servono a classificare i procedimenti in base alla loro durata complessiva.

In base a ciò, si possono distinguere quattro categorie:

1. Inferiore a 287 giorni (categoria verde)
2. Tra 287 e 472 giorni (categoria gialla)
3. Tra 472 e 730 giorni (categoria arancione)
4. Superiore a 730 giorni (categoria rossa)

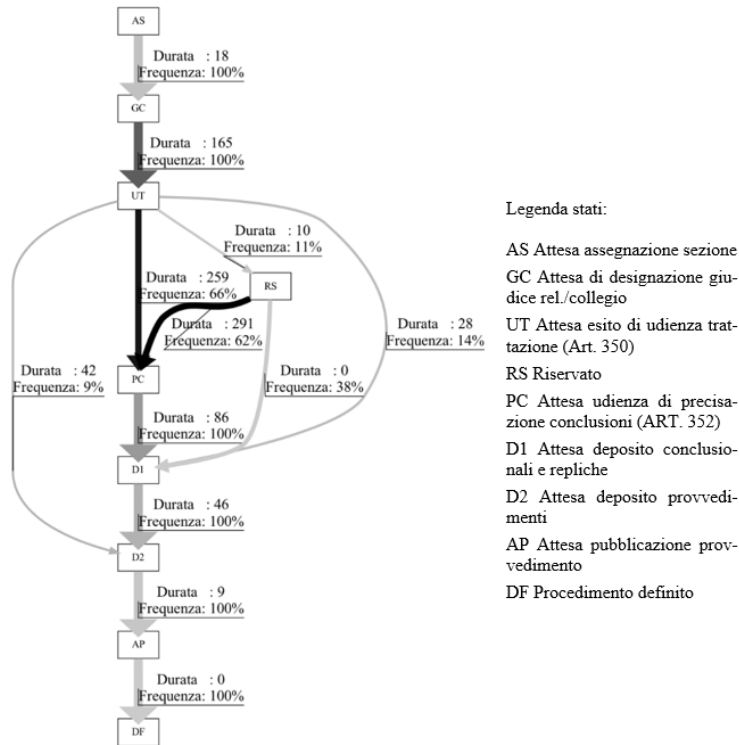
La durata di un processo è calcolata dall'iscrizione a ruolo fino al raggiungimento dello stato di procedimento definito (DF), che indica il completamento del processo.

8.3.4 *Analisi delle varianti dei processi*

In questa parte dello studio, l'obiettivo principale è stato quello di comprendere e visualizzare le diverse varianti dei percorsi processuali attraverso l'analisi del log dei processi. Considerando gli stati percorsi da ciascun processo, abbiamo potuto tracciare i percorsi seguiti dai diversi casi, identificando le varianti più frequenti e le durate medie per ciascuna fase e le transizioni tra le varie fasi del processo. Questa analisi ci permette di evidenziare non solo i percorsi più comuni, ma anche di rilevare eventuali anomalie.

Il grafico nella FIG. 8.1 rappresenta visivamente le transizioni tra i diversi stati (o fasi) dei processi giudiziari, con particolare attenzione alle frequenze e alle durate medie di queste transizioni. Ogni arco nel grafico indica una transizione da uno stato all'altro, con due attributi chiave: lo spessore di ciascun arco, che è proporzionale alla frequenza relativa della transizione tra gli stati (un arco più spesso indica una frequenza più elevata, suggerendo che la transizione è più comune o frequente tra quelle derivanti dallo stesso stato) e l'opacità del colore degli archi, che varia in base alla durata media associata alla transizione. La scala di colori va da tonalità chiare a scure, dove le tonalità più scure indicano una durata media più lunga e le tonalità più chiare una durata più breve. Le etichette associate agli archi forniscono informazioni dettagliate sulla durata media e sulla frequenza di ciascuna transizione.

FIG. 8.1 Varianti principali – Nella figura sono indicati solo gli stati e le transizioni delle 5 varianti più comuni



Fonte: propria elaborazione su dati SICID della Corte di Appello di Milano

Complessivamente, il grafico mostra un numero limitato di varianti (in figura vengono riportate le cinque varianti più frequenti). Questo focus sulle varianti principali serve anche a semplificare la comprensione del grafico, evitando l'eccessiva complessità che potrebbe derivare dalla visualizzazione di tutte le possibili transizioni di stato.

8.4 Modelli previsionali della durata dei processi

Per costruire un modello previsionale del tempo residuo dei processi giudiziari in corso in questo studio abbiamo adottato l'approccio *Long-Short Term Memory* (LSTM), un'architettura di tipo *Recurrent Neural Network* (RNN) ampiamente utilizzata nell'ambito dell'apprendimento automatico di tipo Deep Learning per l'elaborazione di dati sequenziali. Questo approccio è particolarmente vantaggioso nel campo del *process mining*, dove è fondamentale elaborare sequenze temporali di eventi.

Il primo passo della nostra metodologia ha comportato la trasformazione degli eventi giudiziari in un formato compatibile all'analisi tramite reti neurali. In particolare, abbiamo impiegato una strategia di codifica a interi, convertendo ogni evento unico in un valore numerico distinto. Questa trasformazione è stata necessaria per collegare la natura categorica degli eventi giudiziari con la capacità di elaborazione numerica delle reti neurali.

Successivamente, ci siamo concentrati sull'*embedding* di questi eventi codificati. Il livello di *embedding* nel nostro modello LSTM ha mappato gli eventi codificati in interi in rappresentazioni vettoriali dense. Questa rappresentazione è critica in quanto cattura le relazioni tra eventi diversi, posizionando eventi simili in prossimità all'interno di uno spazio vettoriale ad alta dimensionalità. Dopo la codifica e l'*embedding* degli eventi, abbiamo affrontato la lunghezza variabile delle loro sequenze tramite il padding, standardizzando a una lunghezza fissa determinata dalla sequenza più lunga riscontrata nel nostro set di dati di addestramento.

L'architettura del modello comprende un *layer* di *embedding* per la rappresentazione vettoriale degli eventi, seguito da un *layer* LSTM per catturare le dipendenze temporali e un *layer* di output lineare per la previsione. L'obiettivo principale è prevedere il tempo residuo per ciascun evento all'interno delle tracce dei processi. Il modello LSTM è stato addestrato su un set di sequenze di processi giudiziari, dove ogni sequenza rappresenta una serie di eventi con i rispettivi tempi residui. L'output del modello fornisce una previsione del tempo residuo per un determinato evento, considerando il contesto storico fornito dagli eventi precedenti nel processo.

8.5 Risultati

Per sviluppare un modello di analisi accurato, abbiamo proceduto alla divisione dei dati in due insiemi distinti: il training set per l'allenamento del modello e il test set per la sua validazione. Per ridurre il rischio di *overfitting*, e cioè il rischio di derivare un modello molto legato ai dati disponibili e quindi poco generale, questa suddivisione è stata effettuata attraverso un metodo stocastico per assicurare che entrambi i set siano rappresentativi dell'intera varietà di processi giudiziari. A differenza di una divisione basata esclusivamente su criteri temporali, che potrebbe portare a un training set composto unicamente da processi conclusi entro una certa data e un test set costituito da processi successivi, il nostro approccio mira a includere un insieme equilibrato di processi, sia brevi sia lunghi, in entrambi i set. In questo modo si riduce il rischio di introdurre un *bias* legato alla durata dei processi, garantendo che il modello apprenda da e sia testato su un campione rappresentativo dell'intero spettro di processi giudiziari. Abbiamo poi definito un intervallo temporale, dal 1° gennaio 2018 al 1° gennaio 2023, suddividendo questo lasso di tempo in intervalli trimestrali.

Durante ogni intervallo temporale, abbiamo calcolato le previsioni del tempo residuo per i processi attivi utilizzando una rete neurale LSTM e abbiamo classificato i processi nei livelli di criticità indicati nel paragrafo 8.3.1; FIG. 8.2). Abbiamo poi confrontato queste previsioni con i valori reali, calcolando l'errore medio assoluto (MAE) per valutare la precisione del modello (FIG. 8.3).

FIG. 8.2 Classificazione dei processi nei quattro livelli di criticità, basati sul tempo previsto o reale per la conclusione dei processi. Le barre sono divise in due per ciascun periodo: la parte sinistra rappresenta le previsioni del modello LSTM, mentre la parte destra rappresenta i dati reali. I diversi pattern indicano la classificazione in base alle soglie di tempo permettendo un confronto tra previsioni e realtà.




Fonte (per entrambe le figure): propria elaborazione su dati SICID della Corte di Appello di Milano

Abbiamo poi classificato ogni processo in base a soglie temporali predefinite (paragrafo 8.3.3) e confrontato le classificazioni ottenute dal modello LSTM con quelle derivate dai dati reali. Questo confronto ci ha permesso di valutare non solo l'accuratezza del modello in termini numerici, ma anche la sua capacità di classificare correttamente i processi in categorie temporalmente rilevanti. Per calcolare l'accuratezza abbiamo considerato i dati classificati dal modello LSTM e li abbiamo confrontati con i dati reali, periodo per periodo.

In particolare, per ogni periodo temporale analizzato, abbiamo contato il numero di processi che il modello ha correttamente classificato in ciascuna categoria e abbiamo sommato questi conteggi per ottenere il totale dei casi

FIG. 8.3 Andamento dell'Errore medio assoluto (MAE) del modello LST nel corso dei vari trimestri

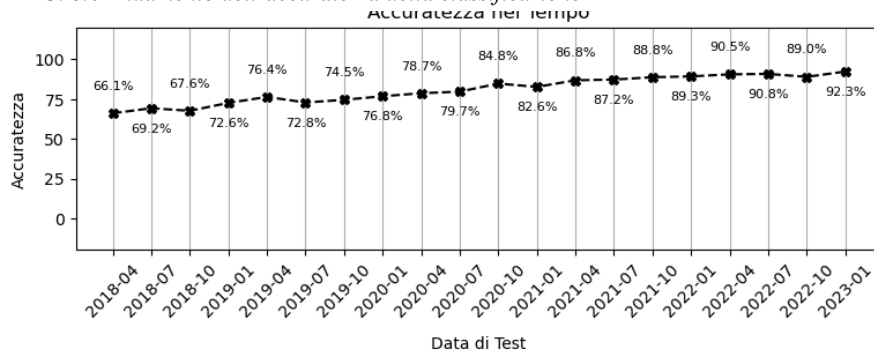


correttamente classificati dal modello. Parallelamente, abbiamo calcolato il numero totale di processi per ciascuna categoria secondo i dati reali, corrispondente al denominatore per il calcolo dell'accuratezza. L'accuratezza complessiva del modello è stata quindi calcolata come la percentuale dei casi correttamente classificati rispetto al totale dei casi reali.

$$\text{Accuratezza} = \frac{\min(\text{valore LSTM}, \text{valore Reale})}{\text{valore Reale}} \times 100$$

In termini numerici, abbiamo ottenuto un'accuratezza complessiva dell'80,32%.

FIG. 8.4 Andamento dell'accuratezza della classificazione



Fonte: propria elaborazione su dati SICID della Corte di Appello di Milano

8.6 Conclusioni

Nel presente studio sono stati sviluppati metodi per analizzare la frequenza e tipologia delle varianti nello svolgimento dei processi ed è stato sviluppato un predittore basato sulle serie storiche degli eventi dei processi e l'oggetto associato alla causa, che consente di stimare il tempo residuo necessario a terminare il processo. Ulteriori sviluppi di questo lavoro potrebbero interessare un approfondimento delle variabili contestuali del processo, esaminando ad esempio la natura della citazione oppure i percorsi anomali che chiedono operazioni di cambiamento di stato per proseguire l'esecuzione del processo, o ancora identificando gli eventi che più hanno impatto sulla lunghezza dell'esecuzione. In questi casi è possibile approfondire i risultati di questo studio tramite tecniche automatiche per l'identificazione di eventi critici e ottenere un miglioramento delle capacità predittive dei metodi di *process mining* prendendo in esame anche variabili legate al contesto.