

利用文本分類技術於刑事判決書之沒收物辨識 Confiscation Detection of Criminal Judgment Using Text Classification Approach

史軒慈 Hsuan-Tzu Shih

School of Big Data Management,
Soochow University, Taiwan
dollyshih39@gmail.com

陳筱詩 Hsiao-Shih Chen

School of Big Data Management,
Soochow University, Taiwan
kellywithchen@gmail.com

邱鈺臻 Yu-Cheng Chiu

School of Big Data Management,
Soochow University, Taiwan
jean199925@gmail.com

吳政隆 Jheng-Long Wu

Department of Data Science,
Soochow University, Taiwan
jlwu@gm.scu.edu.tw

摘要

在沒收制度日漸完善時，掌握法院實際宣告沒收之種類分布將能更瞭解趨勢變化，除可協助立法者制定法律外，亦可提供外界瞭解沒收制度實際運作之情況。為了使人工智慧技術能夠自動化辨識沒收物，降低以人工方式進行判讀所耗費之人力及時間成本。本研究之目的為建立自動化沒收辨識模型，能快速且準確辨識沒收之多標籤類別，提供各界對於沒收資訊之需求，以利後續法條修正或裁量。本研究以刑事第一審判決書為主要實驗數據，根據現行法條規範將沒收物分為違禁物、犯罪工具及犯罪所得三種類別，並進行多重標籤辨識。本研究將採用 Term Frequency - Inverse Document Frequency (TF-IDF) 及 Word2Vec 演算法作為特徵萃取演算法並搭配隨機森林分類器進行建模。另也採用 CKIPlabBERT 預訓練模型進行建模與辨識。實驗結果顯示，採用 CKIPlabBERT 預訓練模型進行沒收物辨識訓練與預測下，在僅依據判決書中所提及沒收字詞之句子時，可獲得最佳的辨識效果，以案件沒收為任務時，Micro F1 分數可高達 96.2716%，以被告沒收為任務時，Micro F1 分數高達 95.5478%。

Abstract

As the system of confiscation becomes more and more perfect, grasping the distribution of the types of confiscations actually announced by the courts will enable you to understand changing of the trend. In addition to assisting legislators in formulating laws, it can also provide other people with an understanding of the actual operation of the confiscation system. In order to enable artificial intelligence technology to automatically identify the distribution of confiscation, and consumes a lot of manpower and time costs of manual judgment. The purpose of this research is to

establish an automated confiscation identification model that can quickly and accurately identify the multiple label categories of confiscation, and provide the needs of all social circles for confiscation information, so as to facilitate subsequent law amendments or discretion. This research uses the first instance criminal cases as the main experimental data. According to the current laws, the confiscation is divided into three categories: contrabands, criminal tools and criminal proceeds, and perform multiple label identification. This research will use Term Frequency - Inverse Document Frequency (TF-IDF) and Word2Vec algorithm as the feature extraction algorithm, with random forest classifier, and CKIPlabBERT pretrained model for training and identification. The experimental results show that under the CKIPlabBERT pretrained model, the best identification effect can be obtained when only use sentences with confiscated words mentioned in the judgment. When the task is case confiscation, the Micro F1 Score can be as high as 96.2716%, and when the task is defendant confiscation, the Micro F1 Score is as high as 95.5478%.

關鍵字：刑事判決、沒收、文本分類、機器學習、預訓練模型、多標籤分類

Keywords : Criminal Cases, Confiscation, Text Mining, Machine Learning, Pretrained model, Multi-label Detection

1 緒論

我國刑法沒收制度在 105 年有了重大變革，沒收對象擴大到第三人，不再僅限於犯罪行為人，販售黑心食品之不肖業者，其違法行為所獲得之不當得利，國人期待以法律剝奪之。此外，違禁物，如毒品，同樣需由法律加以沒收。依內政部警政署統計，12 歲至 23 歲之

毒品嫌疑人，108 年共 5,676 人，顯示毒品潛入校園，戕害青少年身心健康程度不低。而施用毒品所衍生之犯罪問題亦不容忽視。沒收件數於 99 年至 104 年間平均每年約 3.1 萬件，105 年沒收制度變革後，則大幅上升，105 至 108 年間平均每年約 4.3 萬件。顯示修法後，刑事案件宣告沒收之件數大幅提高。

無法以名詞與沒收物類別有對照關係，因為相同之物品，若被告所犯罪名不同，則會有不同之沒收分類，故無法僅以對照表對沒收物進行分類，仍需視判決書內容而定。本研究沒收物之分類是以刑法第 38 條及第 38 條之 1 作為分類基準，若特別法有規定，則從特別法之規定。為了使本研究所建立的模型可使法官撰寫判決書時能作參考依據，故將採用刪除判決書中有關法條之文字，亦即在不知道法條的前提下，進行沒收物之分類。

近年法學上利用機器學習、文字探勘技術與 BERT 模型進行之研究，多集中在量刑因子、量刑系統等方面，尚無應用在沒收物之研究上，目前僅能以人工方式研讀判決書並做標記，其處理效率不佳。若能將文本分類技術應用在沒收物之分類上，便能改善沒收物辨識的人工成本，及提升沒收物統計之效率。此外自動化辨識能更進一步瞭解沒收物種類與所犯罪名之相關性，故掌握沒收物分類之分布，可幫助立法者針對沒收較多之種類，制定更完善的法律規範。本文將以司法院法學資料檢索系統公開之判決書作為資料，透過文字特徵萃取演算法與機器學習模型來建立沒收物多標籤分類模型。另也採用深度學習模型中最新進的 BERT 模型進行建模，期望所建構的模型可以有效辨識沒收物多標籤分類，使非結構化之判決書能夠自動辨識出沒收物類型。本研究將達成以下貢獻：(1) 因本研究是將判決書中有關法條之文字先予刪除，再進行分類，故可提供法官於判決書正本完成前，先行檢視所引法條是否正確，避免事後修正及增加行政成本，亦可提升民眾對司法之信任。(2) 違禁物可能有銷毀之必要，因此可視違禁物之多寡進行更精準之預算編列，犯罪工具或犯罪所得，除法律有規定者外，可進行拍賣或繳庫，本研究可幫助外界瞭解沒收對國庫之貢獻。

2 文獻探討

2.1 我國沒收制度

105 年 7 月以前，刑法第 38 條將沒收物之種類分為因犯罪所生或所得之物、供犯罪所用或犯罪預備之物及違禁物，且刑法從刑之種類分為：褫奪公權、沒收、追徵、追繳或抵償。所謂從刑就是須依附於主刑，主刑存在時，從刑才會存在，也才能宣告沒收，且對於第三人之財產不得進行沒收，亦即沒收主體僅限犯罪行為人。林宗志 (2014) 建議以三種面向改進：建立沒收物之保全機制，避免事先轉移，無法執行沒收；建立第三人參與訴訟機制，保障第三人權益；沒收程序不以定罪為必要。

105 年 7 月起，刑法沒收新制上路，新法讓沒收具獨立性，無須依附主刑，得單獨宣告沒收，且對第三人之財產同樣可執行沒收。惟新法將沒收擴大解釋後，可能產生罰金刑與沒收重複剝奪犯罪所得的疑慮 (陳贈吉，2017)，及沒收金額之計算是否應扣除成本問題。有學者認為應視該法人是否有過失而定 (陳偉倫，2018)，劉韋汝 (2019) 則認為可能被宣告沒收之當事人，若已具備程序上主體地位，皆可能成為本案參與人，不應由實體法的角度判定是否屬於第三人，如此才能確實保障第三人應有之訴訟權利。惟若第三人捨棄參與此項訴訟權利，林宜潔 (2020) 認為效力僅及於聽審權，法院仍可對其宣告沒收，且該第三人亦喪失救濟之權利，對於沒收之判決不得提起上訴。

除了沒收行為人之犯罪所得外，如有其他來源不明且可能源自不明違法行為之所得，亦可宣告沒收。林秉衡 (2020) 認為我國沒收制度之設計，應分為二元體制，分別係犯罪物沒收與利得沒收，其目的分別為危險防衛及犯罪預防，其中犯罪物沒收又含違禁物及犯罪工具產物，然本研究將犯罪工具產物簡稱為犯罪工具，且沒收物之分類依據刑法第 38 條第 1 項、第 2 項及第 38-1 條分為三類。

2.2 文字特徵萃取

TF (Term Frequency) 演算法 (Luhn, 1957) 是計算一個字詞在一篇文章中被提及的次數，但為避免不同文章間做比較時，篇幅較長之文章，字詞出現的頻率必較短篇文字多，因

此演算法做了修正，再除以一篇文章的總字詞數。IDF (Inverse Document Frequency) 演算法 (Spärck Jones, 1972) 是計算一個字詞，在一群文章中所占的篇幅數，若字詞在較少的文章被提及，則該字詞較能代表那篇文章的分類特性。Term Frequency-Inverse Document Frequency (TF-IDF) 為兩者之乘積，用以表示一個字詞出現之頻率及其重要度。謝知庭 (2020) 以 2014 年至 2020 年有關實驗教育之碩博士論文及期刊為研究文本，利用 TF-IDF 進行字詞權重分析，利用潛在狄利克雷分配 (Latent Dirichlet Allocation, LDA)，分別研究各年度代表關鍵字並建立主題模型，提出實驗教育三項法規自公布以來，學者研究分析之主題趨勢。梁家徽 (2020) 針對筆記型電腦研發過程中，需對過程所遇問題排列優先處理程序，因此利用實際發問紀錄，以 TF-IDF 篩選特徵值並建立預測模型，最後搭配類神經網路模型獲得最佳實驗結果，召回率 (Recall) 高達 85%。鍾育東 (2019) 以台灣旅遊論壇「背包客棧」不同地區之討論內容，以 TF-IDF 方法找出背包客最常討論的內容，提供旅遊業者推出符合旅客期待的行程。謝宛芷及胡雅涵 (2014) 為了自動分類資安問題及預測問題嚴重度，利用資訊安全相關新聞進行斷詞，並將字詞給予不同的權重，研究結果顯示使用詞頻加權與類神經網路分類器之 F-Measure 為 97.6%，為所有方法中之最佳。

詞嵌入 (Word Embedding) 技術能將文本資訊嵌入於向量中，用於表達所訓練過的文本語意，Word2Vec 演算法 (Tomas Mikolov 等人, 2013)，是詞嵌入的其中一種作法，目的是將文字轉換為向量數值，供後續機器學習模型使用。Word2Vec 又可分為 Skip-gram 及 CBOW (Continuous Bag of Word) 兩種模式，兩者的差別在於 Skip-gram 是給定中間字詞，預測前後文字，而 CBOW 則是給定前後文字，預測中間文字。陳克威 (2020) 應用於論文推薦系統，在 TF-IDF 及 Word2Vec 兩種方法比較下，Word2Vec 更能推薦潛在的相關性論文，維度低於 100 時，TF-IDF 優於 Word2Vec，當維度逐漸提高，Word2Vec 的表現越來越好，該研究建議維度設定於 200 至 300 間效果最好。林祥慶 (2018) 使用 TF-IDF、Word2Vec 及人工篩選特徵搭配線性迴歸，施

用一級毒品之預測刑期與實際月數平均差 3.08 個月，F1 Score 為 86%，施用二級毒品則平均差 1.60 個月，F1 Score 為 88%，但是運用到較複雜的案件，例如販賣毒品時，則較難準確預測刑期。

2.3 文字探勘在判決書上之應用

目前以刑度預測相關研究為大宗，林琬真等人 (2012) 以 TF-IDF 作為文字重要度，以文字出現之頻率來表示，進行文字加權，其所犯罪名特別選用強盜罪與恐嚇取財罪者，並達到改善案件分類之效果。黃玉婷 (2012) 以智慧財產案件為例，利用正規表示法找出量刑因子之段落，發現文字探勘所產出之因子與人為標記之因子相差無幾。王安定 (2016) 則以毒品相關判決為例，利用 TF-IDF 和 N-gram 解析判決書字詞，並使用線性迴歸及神經網路進行量刑模型之建立，發現線性迴歸用來預測量刑的效果優於神經網路。姜晴文 (2019) 以過往之研究及其判決書樣本特性建立若干欄位，手動標記欄位及親權歸屬，且均依照法官撰寫之裁判書內容作為標記基礎，並使用對數機率迴歸、決策樹 (Decision Trees)、隨機森林 (Random Forest)、梯度型推進決策樹及類神經網路分類器，實驗結果發現五種分類器在預測裁判結果上，準確率均可達 95.5% 以上。

2.4 文本分類模型之應用

黃馨慧 (2013) 以靜態影像訓練臉部表情識別模型、郭家奴 (2014) 建立河流水位即時通報系統、陳時仲 (2015) 評估隨機森林與迴歸模型之效力。葉子維 (2018) 以決策樹、線性判別分析及隨機森林為模型，尋找行動銀行之潛在客戶、蔡宗諺 (2019) 藉由決策樹及隨機森林模型，訓練禪定與休息狀態下之腦電波分類。以上研究均在使用隨機森林演算法時，獲得較好之成效。王厚勛 (2020) 使用 DistilBERT 搭配隨機森林分類器以及 BERT 搭配支援向量機 (SVM) 開發了一款以通訊軟體為基礎的聊天機器人用於金融防詐騙，協助民眾判別其遭遇的情境是否為詐騙，並提供相對應的處理建議。翁嘉嫻 (2020) 使用 BERT 預訓練語言模型來識別網路上的虛假評論，實驗結果顯示 BERT 模型的識別效果

較傳統基於靜態特徵向量之模型要來得精準。曾浚宥 (2020) 透過網路爬蟲蒐集食品廣告違規案例以建立食品廣告違規識別所需的訓練資料，並將訓練資料用以訓練 BERT 模型，其研究結果顯示可以有效地識別食品廣告中的違規詞。

3 研究方法

本研究以文本分類技術作為自動化沒收物辨識系統，主要是針對判決書的文本內容進行斷詞、文字萃取、清楚、建模及分類評估等處理，其中本研究採機器學習分類模型以及 CKIPlabBERT 預訓練模型進行沒收物案例學習，以利建立判決書有關沒收物種類的自動化多重標籤辨識模型，其整體流程如圖 1 所示。

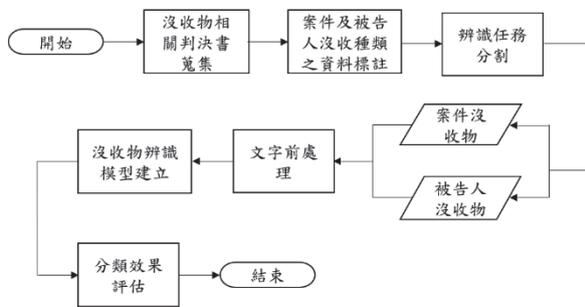


圖 1：本研究方法流程圖

3.1 資料收集

3.1.1 判決書擷取

本研究使用之資料為地方法院刑事第一審判決，且有宣告沒收之判決文本，不使用未宣告沒收之判決文係因是否宣告沒收屬主文應記載事項，若未於主文明確載明宣告沒收，原則上該案件即無沒收適用，因此無須再由分類模型判斷是否沒收，可逕予剔除未宣告沒收之案件。為了獲得本研究所需與刑事沒收相關的裁判書，於是採用司法院法學資料檢索系統之裁判書，搜尋刑事判決中主文中包含「沒收」關鍵字，透過網路爬蟲技術抓取判決書，其中資料欄位含法院別、裁判字號、主文及全文等內容。依刑事訴訟法第 308 條規定，判決書之內文僅規定須分別記載其裁判之主文與理由；有罪之判決書並應記載

¹ 屬違禁物者，係指判決書引用刑法第 38 條第 1 項：「違禁物，不問屬於犯罪行為人與否，沒收之。」；若引用刑法第 38 條第 2 項：「供犯罪所用、犯罪預備之物或犯罪所生之物，屬於犯罪行為人者，得沒收之。但有特別規定者，依其規

犯罪事實，且得與理由合併記載，並無明文規定法官撰寫判決書之撰寫格式，因此本研究所使用的資料屬於非結構化數據。

3.1.2 沒收物標記

本研究根據判決書引用之法條，沒收種類分為違禁物、犯罪工具及犯罪所得¹。上訴所引用之條以外之判決書，則依判決書中沒收段落之描述，以專業法律從業人員進行專業判斷，獲得最終沒收物之歸類。本研究是以判決書引用之法條為標記沒收物種類之準則，因此法條與沒收種類存有一對一之對應關係。為符合分類模型訓練之合理性，以及輔助法官在撰寫判決書時，可作為檢查之用，故訓練分類模型時，所有判決書皆刪除判決書所提到的法律名稱及其法律條號。

3.2 資料分割

本研究依據判決書之特性，將資料集分為兩大任務及三種角度，各自獨立進行實驗，其中兩大辨識任務分別為案件沒收及被告沒收。

(1) 案件沒收：係指取全部被告沒收物種類之聯集，作為該案之沒收物標記；(2) 被告沒收：係以人為單位，分別標記各被告之沒收物種類，例如一案有兩名被告，被告 A 被沒收違禁物，被告 B 被沒收犯罪工具。詳細標記結果如表 1 所示，以案件沒收物標記，分別為違禁物及犯罪工具；以被告沒收物標記，被告 A 標記違禁物，被告 B 標記犯罪工具。另一情況，如案件僅有 1 位被告被宣告沒收，則案件沒收與被告沒收標記結果相同。

標記方式	被告人	違禁物	犯罪工具	犯罪所得
案件	-	1	1	0
被告	被告 A	1	0	0
	被告 B	0	1	0

表 1：案件沒收與被告沒收標記方式，以 110 年度訴字 20 號為例

一般情況下，判決書字數非常多，這將導致模型訓練不易，且多數段落在於描述事實與理由等，因此擷取不同段落之文字，將可能提升辨識精準度，本研究採用三種角度進

定。」，則歸為犯罪工具；若引用刑法第 38-1 條：「犯罪所得，屬於犯罪行為人者，沒收之。但有特別規定者，依其規定。」，則歸為犯罪所得。

行擷取，分述如下：(1) 主文：僅使用主文之文字，判決書其餘文字皆不採用。(2) 沒收句：使用判決書中所有提到「沒收」之句子，若主文有使用沒收文字，則位於主文段之該句亦屬沒收句資料範圍。(3) 全文：使用所有判決書之文字進行後續實驗，不刪除任一文字，文字量為三個角度中最多。

再者分別將三個角度資料集，依裁判日期先後排序，分割成70%作為訓練資料，用於訓練模型；10%作為驗證資料，用於超參數與模型選擇之使用；剩餘20%作為測試資料，用於評估辨識效果。此外若同一裁判日期有數份判決書，則手動調整該筆資料，讓相同裁判日期之判決書分屬相同資料集。根據實驗顯示，需手動調整之資料筆數不超過10件，故影響狀況相當小，仍維持約70%、10%、20%之訓練資料、驗證資料及測試資料。

3.3 文字前處理

因判決書為正式公文，所以撰寫之句型與結構相當完整，故本研究以正規表示式 (Regular Expression) 去除相關法律名稱與條號，刪除前後之文字及標點符號。

3.4 建立模型分類器

3.4.1 建立隨機森林模型

採用 Jieba² 中文斷詞工具進行文本斷詞，以利後續單詞特徵化模型進行轉換。由於斷詞前已將法律名稱及條號相關字串移除，故輸入後續分類模型之文本並未包含任何與法律名稱及條號相關之字串，便利於幫助法官於撰寫判決書時，作為條號引用之輔助工具。

為使機器能夠學習判決書的文本，本研究根據訓練資料集的單詞，採用 TF-IDF 方法產生各判決書之特徵值，利用訓練之資料來獲得必要之特徵，即所有訓練資料中的單詞。再者依訓練所建立之特徵，計算訓練集、驗證資料集及測試資料集之各篇判決書之 TF-IDF 值，並藉由在訓練資料的單詞出現頻率，調整特徵數量多寡，以獲得最佳之特徵數量。

此外，本研究亦使用另一詞嵌入模型進行特徵計算，主要是採用最具規模與應用範圍的 Word2Vec 模型作為詞嵌入演算法，其中以 CBOW 模式進行訓練資料集的學習。本研究亦透過調整詞嵌入的維度大小，產生不同向量大小的詞向量。而在轉換文字至向量詞，本研究採用各篇判決書所採用的文字取得向量平均值，並作為該判決書的特徵向量，相同的轉換過程應用於訓練、驗證及測試資料集。提供後續機器學習模型使用。本研究兩大任務及三種角度均係獨立實驗，因此獨立產生之特徵詞，無論是在 TF-IDF 或詞嵌入皆為獨立計算。

採用 TF-IDF 與 Word2Vec 計算後的特徵與特徵值，並使用機器學習模型進行判決書之沒收物辨識之學習與訓練，以最常見的隨機森林演算法進行建模，建立隨機森林模型，而模型學習目標以沒收物多重標籤為主，預測每一篇判決書時需辨識數個沒收物種類。本研究將針對每個沒收物類別分別獨立訓練一個二元分類器，再以驗證資料實驗結果，選擇最好的參數數據作為最終模型，以進行測試資料之預測，其預測結果將作為最終模型之評估指標。

3.4.2 建立 BERT 模型

由於本研究針對的判決書之內文為繁體中文，所以將使用中央研究院所開發的繁體中文之 BERT 預訓練模型，命名為 CKIplabBERT³，並進行沒收物種類辨識模型訓練。CKIplabBERT 是以標準 BERT 作為網路結構，以字作為訓練單位，因此對文字的前處理不同於傳統的文字特徵轉換法，將每個字轉換成 CKIplabBERT 模型中 Token 編號，並將每個輸入的長度都填充至最長序列，然後使用 CKIplabBERT 預訓練模型以進行判決書之沒收物辨識之訓練，接著預測驗證資料集及測試資料集之沒收物種類，最後將其預測結果作為模型之評估指標。

² 中文分詞工具，採用精準模式進行斷詞。來源：
<https://github.com/fxsjy/jieba>

³ CKIP LAB 所開發之 CKIP Transformers 為繁體中文的 transformers 模型，預訓練模型名稱為 ckiplab/bert-base-chinese。網址：https://huggingface.co/CKIP_lab

4 實驗結果與評估

4.1 實驗資料

本研究從司法院法學資料檢索系統擷取裁判日期介於 107 年 1 月 1 日至 107 年 12 月 31 日，且有宣告沒收者，共計擷取了 41,971 篇判決書。資料分布筆數如表 2 所示，沒收種類表示一件判決書總計被沒收的種類。本實驗數據中僅有 1 種沒收物之比率為 70.17% 最多，有 2 種沒收物之比率為 27.50% 次之，3 種沒收物皆有之比率則為 2.33%，經分割後之各資料集分布情形也大致相同。由於資料是由人工標記之，而 107 年所擷取的判決書就已高達四萬多篇，故僅使用 107 年之資料。

沒收種數	總計件數	訓練集	驗證集	測試集
總計件數	41,971	29,502	4,694	7,775
1 種	29,453	20,674	3,338	5,441
2 種	11,540	8,169	1,256	2,115
3 種	978	659	100	219

表 2：沒收種類占各資料集之分布情形

當一篇判決書中僅宣告沒收 1 種類別時，如表 3 所示以犯罪所得為大宗，占 44.49%，違禁物次之，占 28.57%，犯罪工具占比最低，為 26.94%。雖犯罪所得最多，惟其占比僅占四成四，其餘兩類亦有近三成之比例，因此資料分布尚非偏頗，又由表 3 顯示大部分資料均僅沒收 1 種類別，幸而任一類別之占比差距不大，因此不影響後續實驗效果。

沒收種類	總計件數	訓練集	驗證集	測試集
總計件數	29,453	20,674	3,338	5,441
違禁物	8,415	5,860	996	1,559
犯罪工具	7,934	5,627	810	1,497
犯罪所得	13,104	9,187	1,532	2,385

表 3：一種沒收物之分布情形

當一篇判決書中僅宣告沒收 2 種類別時，如表 4 所示違禁物與犯罪工具、犯罪工具與犯罪所得之組合為多，各占 57% 及 43%，違禁物與犯罪所得之組合最少。而一篇判決書中 3 種類別均同時宣告沒收之分布情形如表 4 最末列所示，占總件數之 20%。

沒收種類	訓練集	驗證集	測試集
總計件數	8,169	1,256	2,115
違禁物+犯罪工具	4,615	731	1,178
違禁物+犯罪所得	70	4	15
犯罪工具+犯罪所得	3,484	521	922

表 4：二種沒收物之分布情形

4.2 實驗設計

本研究所使用之硬體配備相關規格如下：作業系統為 Ubuntu 18.04.5，CPU 為 Intel i7 950 3.07GHz，記憶體為 DDR3 22GB，以及 GPU 為 RTX 3060。本研究使 TF-IDF 及 Word2Vec 兩種方法進行文字轉特徵，在超參數設定上，TF-IDF 設定字詞數量 100 至 5,000 個字詞為主，1,000 字詞，每次間格 100，超過每次間格 500。而 Word2Vec 之向量維度則設定 50 至 1,000，固定每次間格 50。另隨機森林分類演算法，設定決策樹數量為 1,000。CKIplabBERT 模型部分則採用最大 512 個字，學習率為 5e-5，訓練迭代次數為 10 次。

4.3 評估指標

本研究採用分類問題中的 Accuracy 及 F1-Score 進行分類效果評估，本研究目標是多標籤分類，故最後採用各沒收類別的二元分類評估指標的平均值為最終分類效果，即選擇平均 F1-Score 作為模型評估之指標，而平均 Macro-F1 容易受單一類別的影響，故本研究也採用平均 Micro-F1 作為模型評估指標。

4.4 隨機森林模型之分類效果分析

將各實驗於驗證集中表現的最佳結果整理為表 5 和表 6，顯示在驗證集中，不論是採用 TF-IDF 或是 Word2Vec 的方法，驗證資料集之 Macro-F1 分數多數大於分數 Micro-F1。實驗結果顯示六個實驗中，各評估指標皆大於 89% 以上，顯示本研究所提出的方法可以在驗證集中獲得非常優秀的多標籤分類效果。

在案件沒收方面，如表 5 所示，以 TF-IDF 特徵萃取法在驗證集中效果較佳，不論輸入之文字量多寡，均優於 Word2Vec 演算法；在資料的選擇上，以沒收句效果表現最好，這是因為使用主文會因為資訊量不足，不容易辨識沒收物之種類，而使用全文又因資訊量過多，雜訊也較多，反而影響分類效果，但

沒收句是整篇判決書中所有提到沒收的句子，因此較不會受影響。沒收物結合 TF-IDF 可獲得 Micro-F1 分數至高達 96.7038%，Macro-F1 分數亦達 96.8168%。

文本	特徵法	Macro-F1	Micro-F1
主文	TF-IDF	95.0185	94.9128
	Word2vec	92.6038	92.4377
沒收句	TF-IDF	96.8168	96.7038
	Word2vec	93.9458	93.7520
全文	TF-IDF	96.1669	96.0110
	Word2vec	90.6409	90.4168

表 5：案件沒收任務於驗證集之隨機森林模型評估

在被告沒收方面，如表 6 所示，以 TF-IDF 特徵萃取法在驗證集中效果較佳。在資料的選擇上，仍是以沒收句效果表現最好。沒收物結合 TF-IDF 可獲得 Micro-F1 分數至高達 96.6757%，Macro-F1 分數亦達 96.8123%。

文本	特徵法	Macro-F1	Micro-F1
主文	TF-IDF	95.3112	95.1939
	Word2vec	92.8588	92.6777
沒收句	TF-IDF	96.8123	96.6757
	Word2vec	94.0070	93.7603
全文	TF-IDF	96.3717	96.1613
	Word2vec	89.7311	89.3409

表 6：被告沒收任務於驗證集之隨機森林模型評估

4.5 CKIPlabBERT 模型之分類效果分析

在案件沒收的部分，各個實驗在驗證集效果顯示於表 7，其分類的效果在資料的選擇上，皆以沒收句之效果為最佳。其 Micro-F1 分數至高達 96.5796%，Macro-F1 分數亦達 96.6243%。

文本	Macro-F1	Micro-F1
主文	93.4420	93.3244
沒收句	96.6243	96.5796
全文	96.0123	95.9777

表 7：案件沒收任務於驗證集之 BERT 模型評估

在被告沒收的部分，各個實驗在驗證集效果顯示於表 8，其 Micro-F1 分數至高達 96.2059%，Macro-F1 分數亦達 96.3096%。

文本	Macro-F1	Micro-F1
主文	92.2302	92.3913

沒收句	96.3096	96.2059
全文	94.1776	94.0444

表 8：被告沒收任務於驗證集之 BERT 模型評估

整體而言，BERT 模型預測之結果與隨機森林模型在驗證集所得之分析結果大致相同，仍是沒收句資料範圍得到最佳效果。

4.7 隨機森林模型與 CKIPlabBERT 模型之分類效果比較

本研究所採用的隨機森林與 CKIPlabBERT 模型預將用於辨識測試集之效果，其結果統整於表 9，評估結果顯示在案件沒收任務時，CKIPlabBERT 模型之分類效果較機器學習模型佳，兩者之 Micro-F1 分數相差 0.0739% 和 Accuracy 分數相差 0.6688%，但 Macro-F1 分數較差，相差 0.0579%；標記方式為被告沒收時，在三個評估指標上，都是隨機森林模型之分類效果較 CKIPlabBERT 模型佳。由此實驗結果可得知，刑事案件之沒收物辨識，無論是以案件為單位還是被告為單位，都能夠有著相當良好的多標籤分類效果。

任務	模型	評估指標		
		Accuracy	Macro-F1	Micro-F1
案件沒收	隨機森林	90.7653	96.3269	96.1977
	CKIPlabBERT	91.4341	96.2690	96.2716
被告沒收	隨機森林	90.4517	96.2679	96.0950
	CKIPlabBERT	88.8603	95.6722	95.5478

表 9：隨機森林模型與 CKIPlabBERT 模型在測試集之比較

5 結論

本研究所提出的自動化沒收辨識模型確實可有效辨識多標籤任務且獲得相當良好的效果。無論以案件沒收或被告沒收為任務時，在隨機森林和 CKIPlabBERT 模型均證實可獲得 95% 至 96% 左右的 F1 分數。而隨機森林模型採用特徵萃取演算法方面，可得知 TF-IDF 演算法獲得比 Word2Vec 演算法還要好的分類效果，其約有 3% 至 5% 差距。本研究所提出之模型可以提供法院於判決正本製作前，檢視沒收引用之法條是否有錯誤情況，這樣的輔助辨識下，可提升民眾對司法之信任，並協助立法者瞭解沒收物種類之分布，成為往後修訂相關法律之依據，藉由沒收之宣判，有效

降低犯罪率，達到預防犯罪之目的。此外司法院法學資料檢索系統基於保護當事人隱私原則，並非所有判決書都會公開於網路供大眾檢索，因此模型缺少特定類型判決書之訓練，故降低模型分類效果。另一方面，為了使判決書易於理解，司法院於 108 年 5 月鼓勵法官減少使用艱澀字詞，因此或有裁判書因簡化內容或改變用字遣詞，這將有可能影響模型分類準確度。但因無法確切證實法官所撰寫之判決書是否有艱澀字詞或用字遣詞的簡化，這仍需要待確認後，再行本研究所提模型以進行驗證，這樣才能夠知曉該限制影響模型分類準確度的程度為何。未來研究可考慮使用更符合長篇文章的 BERT 模型，以獲得更全面的字詞，避免因 BERT 模型的字數限制而錯失更具辨識度的字詞。

參考文獻

- H. P. Luhn, 1957. A statistical approach to mechanized encoding and searching of literary information. *IBM Journal of Research and Development*, 1(4):309-317.
- S. Jones, K. 1972. A statistical interpretation of term specificity and its application in retrieval. *Journal of Documentation*, 28(1):11-21.
- T. Mikolov, K. Chen, G. Corrado, and J. Dean. 2013. Efficient estimation of word representations in vector space. CoRR abs/1301.3781.
- 王安定，2016，判決書之探勘分析與量刑迴歸模型之建立~以法院毒品判決書為例。臺北市立大學資訊科學系碩士在職專班碩士論文，台北市。
- 林宗志，2014，犯罪所得沒收與保全制度之研究-以程序規範為中心。輔仁大學法律學系碩士論文，新北市。
- 林宜潔，2020，犯罪所得之第三人沒收程序。國立臺北大學法律學系碩士論文，新北市。
- 林秉衡，2020，犯罪物沒收之研究。國立政治大學法律學系碩士班碩士學位論文，台北市。
- 林祥慶，2018，基於判決文之量刑系統設計與實作。國立中正大學資訊工程研究所碩士論文，嘉義縣。
- 林琬真、郭宗廷、張桐嘉、顏厥安、陳昭如、林守德，2012，利用機器學習於中文法律文件之標記、案件分類及量刑預測。中文計算語言學期刊, 17(4) P49-P67。
- 姜晴文，2019，法律資料分析的優化與應用：以離婚後未成年子女親權酌定的裁判為素材。國立臺灣大學法律學系法律學研究所碩士論文，台北市。
- 郭家奴，2014，隨機森林在河川水位即時預報之應用。國立成功大學水利及海洋工程研究所碩士論文，台南市。
- 陳克威，2020，基於 Word2Vec 的學術論文推薦系統。國立東華大學資訊工程學系碩士論文，花蓮縣。
- 陳時仲，2015，隨機森林模型效力評估。國立交通大學統計學研究所碩士論文，新竹市。
- 陳偉倫，2018，沒收制度之變革—以法人沒收為中心。東吳大學法律學系碩士班碩士論文，台北市。
- 陳贈吉，2017，刑法新修正沒收規定之檢討。國立臺灣大學法學院法律學研究所碩士論文，台北市。
- 黃玉婷，2012，以文字探勘技術產製求量刑因子之研究—以我國智慧財產權法律為中心探討。東吳大學法律學系碩士在職專班科技法律組碩士論文，台北市。
- 黃馨慧，2013，以隨機森林架構結合臉部動作單元辨識之臉部表情分類技術。國立清華大學電機工程學系碩士論文，新竹市。
- 葉子維，2018，顧客消費行為分析及行動銀行使用預測-決策樹、隨機森林與判別分析之比較。國立臺北大學統計學系碩士論文，新北市。
- 劉韋汝，2019，沒收特別程序參與主體之探討。國立清華大學科技法律研究所碩士論文，新竹市。
- 蔡宗諺，2019，隨機森林應用於禪定與放鬆休息腦電波之頻率空間特性分類。國立交通大學電控工程研究所碩士論文，新竹市。
- 謝宛芷、胡雅涵，2014，文字探勘技術用於資安事件之自動化分類。電腦稽核期刊，第 29 期，P92 - 101。
- 王厚勳，2020，以 BERT 搭配機器學習研發反詐騙聊天機器人。國立中興大學資訊管理研究所碩士論文，台中市。
- 翁嘉嫻，2020，使用 BERT 預訓練模型識別網路上之虛假評論。國立中興大學資訊管理學系所學位論文，台中市。
- 曾浚宥，2020，訓練 BERT 模型以識別食品廣告中的違規詞。淡江大學資訊工程學系碩士班學位論文，新北市。