

老年扶養費請求案件之准駁及扶養金額預測 Predicting Judgments and Grants for Civil Cases of Alimony for the Elderly

劉威志 Wei-Zhi Liu

吳柏憲 Po-Hsien Wu

林泓任 Hong-Ren Lin

劉昭麟 Chao-Lin Liu

國立政治大學資訊科學系

Department of Computer Science, National Chengchi University

{109753157, 111753120, 109753156, chaolin }@g.nccu.edu.tw

摘要

有鑒於近年請求扶養費民事訴訟案件逐年上升之趨勢，考慮伴隨著調解件數增長，未來量能或將難以負荷，本研究將以斷詞及向量化後之段落以 logistic regression 為基礎提出扶養費准駁預測模型，同時提出使用 model tree 建構扶養金額預測模型，以期未來能在庭外調解時提供一相對客觀的試算結果供有扶養費爭議之兩造參考並儘早達成共識，亦或給予法官參考數據輔助以期能加速判決之進程，進而減少司法資源的浪費。

Abstract

The needs for mediation are increasing rapidly along with the increasing number of cases of the alimony for the elderly in recent years. Offering a prediction mechanism for predicting the outcomes of some prospective lawsuits may alleviate the workload of the mediation courts. This research aims to offer the predictions for the judgments and the granted alimony for the plaintiffs of such civil cases in Chinese, based on our analysis of results of the past lawsuits. We hope that the results can be helpful for both the involved parties and the courts. To build the current system, we segment and vectorize the texts of the judgement documents, and apply the logistic regression and model tree models for predicting the judgments and for estimating the granted alimony of the cases, respectively.

關鍵字：判決預測、民事案件，給付扶養費

Keywords: legal judgment prediction, civil case, the issues of alimony

1 引言

有鑒於請求給付扶養費訴訟有逐年增加趨勢，人工智慧於法律領域之相關應用日漸重要，於是本研究提出二個與扶養費金裁判相關之預測模型，分別為「請求准駁預測模型」和「扶養金額預測模型」，前者預測一案件是否通過或駁回扶養請求；後者則預測一案件之扶養金裁判金額。

本研究採用自民國 89 年至民國 110 年間與扶養費相關案件過濾上訴、離婚及協議相關案件，進行扶養金准駁預測與金額預測。

本文所提「兩造」為扶養金額案件中請求扶養之「聲請人」與被請求扶養之「相對人」此二身份，其可能為配偶、父母、子女亦或手足等關係，此類家事案件往往在調解中關於「是否具扶養義務」與「扶養金額是否適當」有所爭執及論點攻防，因此我們針對兩造主張部分進行准駁預測；針對相關客觀特徵進行金額預測，供兩造及法官參考，以利加速調解及裁判之進程。

實驗中會先擷取特定段落即兩造主張之段落，進行斷詞與向量化之前處理，再使用准駁預測模型進行訓練與預測案件是(准許請求)否(駁回請求)通過扶養金額之聲請。針對「不同預測模型」及「是否模糊化」進行 F1 score 比較。

其次，關於扶養金額預測部分會先進行相關特徵之提取，諸如：聲請人現居地月均支出、聲請人每月補助、聲請人每月要求之金

額等 (詳見本文段落 7)，以利進行初步試算，再使用其他特徵，如：相對人經濟狀況及兩造關係 (是否具相應扶養義務) 等特徵進行輔助調整 (詳見本文段落 8.2)，並得出最終預測金額結果。

關於實驗結果比較，我們採用：僅給予特徵提取之 scikit-learn¹ 的 linear regression、只使用 model tree 進行預測區分且每個區塊單純使用 scikit-learn 的 linear regression 及本文模型，三者進行比較，以比對「是否使用 model tree」、「是否使用多種預測方式」之 mean absolute error (以下簡稱 MAE) 結果優劣。

關於文章架構，本文段落 2 提及關於本實驗的相關研究；段落 3 敘述本實驗的資料來源與篩選；段落 4 講述准駁預測之前處理；段落 5 則介紹准駁預測模型實驗設計；段落 6 則為準駁預測實驗結果比較。段落 7 陳述扶養金預測之前處理與特徵提取；段落 8 則介紹金額預測模型設計；段落 9 為金額預測模型實驗結果比較；段落 10 為上述二模型之實驗總結；段落 11 則為本文結語。

2 相關研究

人工智慧技術應用於法律領域不論在國內或國外都有許多的前沿研究，其應用層面有很多方向，而應用於裁判預測上更是數不勝數，目前在這領域中以刑事案件為主流，以國內為例：像是林婉真等 (2012) 提出將構成特徵要素作為特徵，利用 additive regression 預測強盜及恐嚇取財之量刑結果。然而裁判預測應用在民事案件上目前是相對少見的。

以民事案件來說近期有何君豪 (2021) 提出導入機器學習演算法的建議，再依據繁簡分流理論進行導入 AI 法官的民事訴訟類型選擇，希望能為我國民事訴訟導入 AI 法官提供具體可行的藍圖。王道維等提出 AI 輔助親權判決預測²，其系統藉由輸入夫妻雙方的有利與不利條件後，進行小孩的監護權判給某一方之機率預測。而黃詩淳等 (2020) 的研究則是在探討直接將法律裁判原文輸入機器後，觀察機器能否了解法官的語意並進行親權酌定。

Muhlenbach et al. (2020) 的贍養費裁判預測，該研究在避免過多的法律特徵與避免使用較不具解釋性之 AI 模型的前提下，提出利用隨機森林 (random forest) 與回歸模型對於離婚案件中的贍養費進行預測。

而黃詩淳 (2022) 同時提出透過特徵提取來進行分類決策樹與回歸決策樹之扶養預測，其與本研究相似於預測應用方面，不過其中的特徵提取與模型則有所不同，本研究受到前者 Muhlenbach et al. 之啟發，選擇家事案件中給付扶養費判例作為實驗對象並以兩造主張為基礎提出同請求通過與否關聯之准駁預測模型，以及試算通過數額之扶養金額預測模型，並在提取相對客觀及有限的特徵且避免缺乏解釋性之前提下建構其 model tree (Malerba et al., 2004) 分支條件，再根據林玠鋒 (2015) 對於酌定扶養費的研究去改善與調整我們的預測模型，望能在提供預測結果時亦提出令人信服之特徵解釋。

3 資料來源與篩選實驗對象

本研究使用的資料主要來自臺灣司法院資料開放平臺³，收集了自民國 89 年 1 月起至民國 110 年 12 月之裁判書。裁判書為 JSON 格式檔案，其 key 值會包含「案由、裁判字號、裁判年份、裁判書內文」等，因此本實驗選用案由含有「扶養費」但不包含「返還扶養費代墊款」及「酌減扶養費」之案件，其再進行篩選，篩選規則如下：將裁判字號含有「抗、上、高等、最高、婚」等字眼，因此類字號屬於上訴、抗告審、程序事由與其他類型案件，這些案件並非在本實驗研究範圍內，並過濾裁判書內文中段落不足或未有提及兩造主張之案件，以利後續准駁預測模型訓練。

根據上述過濾條件得出基本語料共 1,930 案件，即是准駁預測模型之實驗對象，其中未通過數量則為 983 件；通過案件數量為 947 件。

¹ <https://scikit-learn.org/stable/>

² <https://custodyprediction.herokuapp.com/userPredict>

³ <https://opendata.judicial.gov.tw>

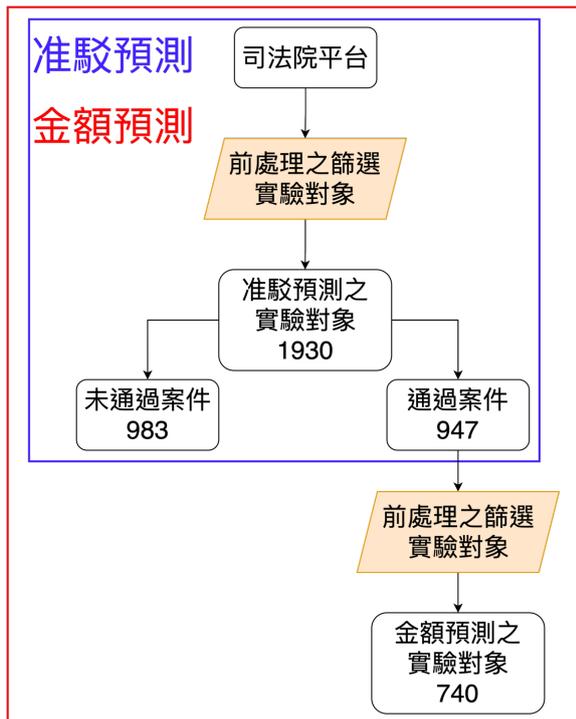


圖 1. 實驗對象之過濾

故會對通過案件中再對具私下調解或協議性質及一次性給付之案件進行過濾，過濾後所剩案件為742件，即本文金額預測模型之實驗對象。其流程如圖1。

4 准駁預測之前處理

經由前段所述之資料篩選過後須要再對裁判書內文做進一步地清理以得出實驗所需資料。裁判書內文含有主文及理由(或是事實、事實及理由要領等詞語)之標題段落，而主文段落為記錄法院最終裁判結果；理由段落則會含有兩造的主張(即聲請人的聲明和相對人的抗辯)與法院裁判之理由等，其中實驗所需的輸入資料來自理由段落，而標記資料則來自主文段落。

4.1 資料擷取

裁判書在撰寫上未有嚴格限制，經過分析後我們發現每個標題內的段落會以多種章節標號做條列敘述，如：「『壹、』」、「『⊖』、

例子	識別標籤	替換文字
劉大明	PERSON	某人
文山區	LOC	某地
台北市	GPE	某地

表 1. 命名實體替換標籤

『(-)』、『甲、』等，因此透過正規表示式法(regular expressions)將理由段落切割成各個章節段落，在經觀察案例後得出法官會以特定的格式來描述聲請人或相對人的主張段落，通常以「聲請人意指略以」或「相對人則以」等來進行開頭，因此我們以其來擷取主張內容即為本研究提出的准駁預測模型所使用的輸入資料。

4.2 資料模糊化與向量化

為了搭配後續的向量化，要先將切割好兩造主張之段落經中研院開源的工具CKIP⁴進行斷詞與命名實體辨識(named-entity recognition, NER)，將主張段落進行斷詞時，會先設置強迫斷詞之詞彙，例如：聲請人、相對人、本件、略以等，以避免出現斷詞錯誤。又因裁判書的內容會出現地點、人名、時間等特殊資訊，不利推廣到所有案件，於是將地名與人名改成「某地」和「某人」如表1，然而時間的部分未用命名實體辨識，因套件會將年齡也歸類為時間，故時間的替換是用正規表示式法來抽取並替換成「某時」，接著進入後續向量轉換。

其中將主張段落透過兩種方法來進行文字向量化，包含TF-IDF⁵與Sentence-BERT(Nils Reimers et al., 2019)，以下簡稱SBERT⁶。前者透過統計文件中的詞頻(term frequency)以及逆向文件頻率(inverse document frequency)，將兩者分數相乘得其評估分數同時也視其為向量。而後者是使用了孿生網路(siamese network)及三連體網路(triplet network)為架構，比較多種目標函數及整合特徵向量的方法，最終可直接輸出該句之句向量(sentence embedding)，以利後續實驗進行。

⁴ <https://ckip.iis.sinica.edu.tw>

⁵ http://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfVectorizer.html

⁶ <https://www.sbert.net>

Vectorize	Model	Blur	F1 score
TF-IDF	naïve-Bayes	F	0.612
TF-IDF	naïve-Bayes	T	0.632
TF-IDF	Logistic	F	0.669
TF-IDF	Logistic	T	0.788
SBERT_AVG	NN	F	0.660
SBERT_AVG	NN	T	0.690
SBERT+LSTM	NN	F	0.555
SBERT+LSTM	NN	T	0.649

表 2. 准駁預測模型模型比較

5 准駁預測模型實驗設計

由於法官會參考兩造說法及所提的相關事證後進行裁判，因此我們擷取出兩造主張之段落後，經由上段提及之向量化方式來進行向量轉換。望能透過不同向量化的方法及搭配不同的預測模型，從中找到較適合扶養金准駁預測之模型，實驗中的資料切割都是以 8 比 2 的方式來進行切分訓練資料與測試資料。

5.1 向量化設定

透過 scikit-learn 的 TF-IDF 進行向量轉換時，會設置停用詞來避免統計無意義的詞彙，其維度在是否使用模糊化的效果下分別約為 18,000 多維與 24,000 多維。

SBERT 之預訓練模型本實驗選用“distiluse-base-multilingual-cased-v1”因其訓練資料才有使用繁體中文且表現較其他也有使用繁體中文的預訓練模型來得佳，不過由於 SBERT 會有字數上的限制 (128 個字)，所以會將主張段落以「。！？；」四種標點符號進行斷句將其切割成多個句子，並進一步向量轉換得出多個句向量，其向量維度為 512 維。

5.2 准駁預測模型參數設定

TF-IDF 向量化方式會搭配 scikit-learn 提供的 naïve-Bayes 與 logistic regression 來進行預測通過與否，其參數按照預設值進行訓練。而 SBERT 向量化方式則會將多個句向量進行平

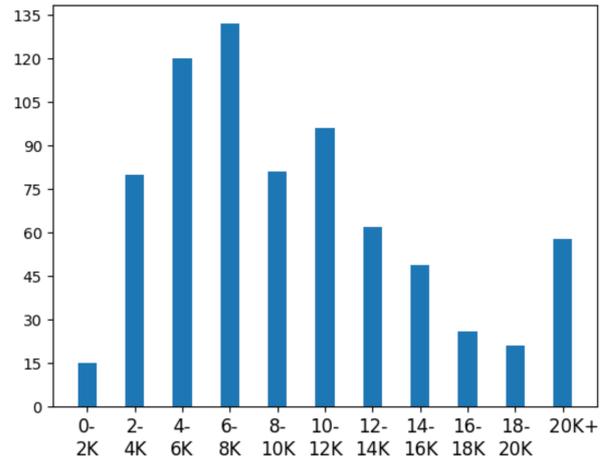


圖 2. 為真實扶養金額分佈

均加總或用 LSTM 進行串接，其串接方式會以最多句子數之段落為基準，若有段落句子數小於其數量則會進行 padding，以其能不影響訓練又能不失去最多句子數之資訊，接著使用 PyTorch⁷之框架進行准駁預測訓練，其中會以 Adam 為優化器，並將起始的學習率設定為 2e-3，loss function 使用 PyTorch 提供的 Binary Cross Entropy，batch_size 設為 32，epoch 則設為 10。

6 准駁預測模型結果

預測結果如表 2 所示。由下表可見，在資料規模較小的情況下，TF-IDF 搭配 logistic regression 會較 SBERT 轉換向量來得好，其 F1 score 會來到 0.788。

理論上當新案例進入該准駁預測模型後，若判斷為不駁回者才繼續進入下文所提之扶養金額預測模型，但此研究為了更準確地建構金額預測模型，故不採用准駁預測模型模型判斷後分類為通過之案例，而是採用真實通過且經前段 (本文段落 3) 所提條件過濾之案例。

7 扶養金額預測之前處理與特徵提取

圖 2 為真實扶養金額分佈圖，真實扶養金額之均值为 9606.95 元，其中扶養金的金額預測我們以客觀特徵為基礎並以「按月給付」之金

⁷

https://pytorch.org/tutorials/beginner/basics/buildmodel_tutorial.html

特徵名稱	簡稱	定義
Consume	C	聲請人現居地平均每人每月消費支出、最低消費基準
Grant	G	聲請人每月補助金
Others	O	聲請人每月額外所需開銷
Ask	A	聲請人請求之金額
Persons	P	相對人數
numChilds	N	具扶養義務之人數
Income	I	相對人之每月收入總和
Estate	E	相對人之財產總和
n_income	N_I	扶養義務人之每月收入總和
n_estate	N_E	扶養義務人之財產總和

表 3. 主要特徵

額為主要預測結果，其中若相對人為複數時，實驗中會視多個相對人合併為一個相對人，因此將主文段落中所有相對人各自「按月給付」之金額進行加總，作為模型預測之對照真值。

再以人工進行 8 種主要客觀特徵之提取，會使用此 8 種主要特徵的原因在於觀察到法院裁判之理由段落是以這些特徵為主要考量計算，但由於此模型望能在將來提供兩造進行調解，而此階段並不會有法官參與，因此所謂客觀特徵便是在避免擷取到法院裁判之理由段落中法官的考量，其會根據自己的心證得出聲請人所需的扶養金額。而採用人工提取特徵是為了確保提取之準確，避免給予模型不正確的特徵值，提取概要如以下所述。

Consume，以下簡稱 C，以行政院公佈之各縣市人月均消⁸為基準，代表聲請人每月之可能開銷。

Grant，以下簡稱 G，以裁判書中聲請人自承或法官依職權調閱補助領取紀錄，係代表聲請人每月可用於補貼開銷之金額。

Others，以下簡稱 O，以聲請人自承並附以相關物證(如收據)或人證(傳換證人之證稱)，其表聲請人每月額外開銷，以上三者係構成聲請人每月開銷之主要客觀特徵。

Ask，以下簡稱 A，則為聲請人主觀認定每月所須之生活所資。

Persons，以下簡稱 P、Numchilds，以下簡稱 N，則分別為該案件中相對人數及具扶養義務人數，可用於計算案件中相對人須負擔扶養金額之比例，因此本模型首先會對上述特徵進行判斷預測其可能之初步裁判金額。

Income，以下簡稱 I、Estate 以下簡稱 E，分別代表相對人月收及財產，皆為法官依職權調閱之年度財產所得申報資料，即相對人之財力狀況與負擔能力，並可能影響扶養金額調整，因此本模型會採用客觀數據(行政院公佈之國民所得中位數⁹及基本薪資¹⁰)及其他特徵來進行來對初步裁判金額進行分類，區分是否需進一步調整。

N_income，以下簡稱 N_I、N_estate，以下簡稱 N_E，代表扶養義務人之財力狀況即負擔能力，並可能影響扶養金額調整，最終調整之部分會採用 N_I、N_E 及聲請人離家等其他客觀特徵來進行來對需調整案件之裁判金額進行最終調整。

以上主要特徵資訊整理如表 3，其次林玠鋒(2015)有提出法官會因聲請人的不良行為或相對人的財力狀況而對扶養金額有所調整¹¹，因此我們將其稱為輔助特徵，並將其整理如表 4 所示。

然而在實務上並不會預先有判決書，所以我們假設在庭外調解時，兩造可如實告訴此模型相關特徵，而在庭上調解時由法官依職權調取資料以及關係人之證詞進而抽取該特徵來進行預測。

8 金額預測模型設計

本實驗金額預測模型即為一 model tree，透過特定規則將案件歸屬於某個分支，若分到最

8

<https://www.stat.gov.tw/ct.asp?xItem=40875&ctNode=511&mp=4>

9

<https://www.dgbas.gov.tw/ct.asp?xItem=47996&ctNode=562>

4

10

<https://www.mol.gov.tw/1607/28162/28166/28180/28182/28184/29016/>

¹¹ 民法 1115、1118、1118-1、1119，家事事件法 99~103、107.1、126

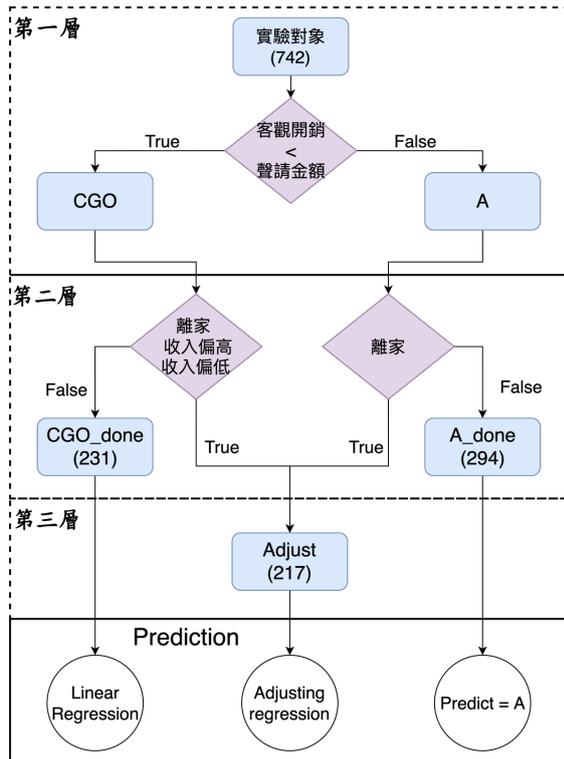


圖 3. 金額預測模型架構

終節點時則進入該節點的預測模型，各層功能大致上為：試算初步裁判金額、決定是否進一步調整金額、需調整者對其進行調整，大致架構如下列各點所述及圖 3 所示。

8.1 Model tree 各層設計

P 第一層先試算出聲請人每月客觀所需開銷 $(C - G + O)$ 再乘以相對人對於具扶養義務人之佔比 (P/N) ，稱其為客觀金額。

$$\text{客觀金額} = (C - G + O) \frac{P}{N} \quad (1)$$

並與 A 進行比較大小，若試算金額較小則歸為「CGO」，反之則歸為「A」，若兩者相同則歸為「A」，依此區分出「CGO」及「A」兩部份。

第二層則繼前一層區分出「CGO」和「A」後，要再進一步區分是否需進行調整，區分條件如下：「CGO」部分的案件會考量聲請人是否有離家、賭博、酗酒及家暴等事由，且以訴訟開始年份之國民最低薪資與中位數薪資判斷相對人之財力狀況。

「A」部分則因聲請人要求已比客觀數據來得低(見圖 3 第一層判斷)，若非聲請人對相對人有未盡扶養之事實，法官不太會再根據相

特徵名稱	簡稱	定義
Adjust_label_1	A1	聲請人是否有不良嗜好或積欠債務
Adjust_label_2	A2	聲請人是否被相對人家暴
Adjust_label_3	A3	聲請人是否有家暴行為
Adjust_label_4	A4	聲請人是否離家未善盡照顧相對人
Higher income	H_I	相對人人均月薪是否比該年薪資中位數高
Lower income	L_I	相對人人均月薪是否比該年最低薪資低
Rate of Income	R_I	$\frac{I/P}{N_I/N}$
Rate of Estate	R_E	$\frac{E/P}{N_E/N}$

表 4. 輔助特徵

對人財力狀況進行調整，因此只針對聲請人有離家、賭博、酗酒及家暴等事由進行判斷。

若判斷後不需調整則歸為「Done」其預測結果即為初步預測金額，反之則歸為「Adjust」便會進入下一層進行調整。

關於第三層，除上述二層提及之主要特徵外，會再多增加考量聲請人之不良行為或相對人之於所有具扶養義務人財力比較等 8 個輔助特徵(參考表 4)，以此針對「Adjust」之預測金額進行調整。最終該模型呈現三個分支並在各分支使用不同預測方式，最後會將各分支 MAE 進行加權計算以得出整體模型之結果。

8.2 Model tree 各分支對應預測方式介紹

關於上段所提三支之預測方式如下：

「A_done」分支中案件已比相對客觀之主要特徵來得低，表示聲請人可能已考量其他因素後所提出的聲請金額，且法官無其他理由進行上調，而下調者則應會在第二層(圖 3)區分至「Adjust」故可直接採用聲請人要求之金額作為最終預測之結果。

關於「CGO_done」，由於以客觀特徵試算出的金額仍可能有些微波動，故會將此分支以 8 比 2 方式切割訓練資料與測試資料並丟入 scikit-learn 的 linear regression 進行隨機 split 訓練，其回歸預測即為最終預測之結果。

Data_group (num)	Only SKL LinearRegs.	SKL with M.T.	本文模型
Ask_done (294)	-	1961.45	1351.29
CGO_done (231)	-	1935.77	1935.77
Adjust (217)	-	3170.60	3033.98
Total (742)	2751.78	2310.73	2028.02

表5. 各模型MAE比較

「Adjust」分支模型我們以倍率調整的構思進行設計，因此我們提出：

$$Predict_i = X_i * \prod_{j=1}^8 Features_j^{weight_j} \quad (2)$$

，不過我們會進行對數轉換，轉換成：

$$\log Predict_i = \log X_i + \sum_{j=1}^8 weight_j * \log Features_j \quad (3)$$

以利進行回歸預測，其中 i 為案件， X_i 為初步預測金額。

以下進行舉例說明，假設第三層train完後的 $weight=[0.2, 0.3, -0.5, -0.6, 0.1, -0.2, 0, 0.4]$ ，且某案件第一層初步預測結果為100又該案輔助特徵=[1, 1, 1, 2, 1, 1, 1.2, 1.2]，則其調整為：
 $100 \times 1^{-2} \times 1^{-3} \times 1^{-5} \times 2^{-6} \times 1^{-1} \times 1^{-2} \times 1.2^0 \times 1.2^{-4}$
 $= 100 \times (1 \times 1 \times 1 \times 0.66 \times 1 \times 1 \times 1 \times 1.0756)$
 ≈ 70.96
 並將70.96作為最終預測結果。

當前六者 (A1 到 A4, H_I, L_I) 為是時，標註為 2，為否則標註為 1；後二者 (R_I, R_E) 則如表 4 之計算。

由上述舉例可見當特定輔助特徵之 training weight 為 0 或其標註為 1 時並不會影響調整，故我們利用此對數特性提出該分支模型。

9 扶養金額預測結果比較

本研究以不用 model tree 且單純使用 scikit-learn 的 linear regression (以下簡稱 Only SKL LinearRegs.)、使用 model tree 且每個分支一樣單純使用 scikit-learn 的 linear regression (以下簡稱 SKL with M.T.) 及本文模型進行實驗結果比較。

Only SKL LinearRegs. 採用全部通過案件資料及上述提及之特徵，並不使用 model tree 進

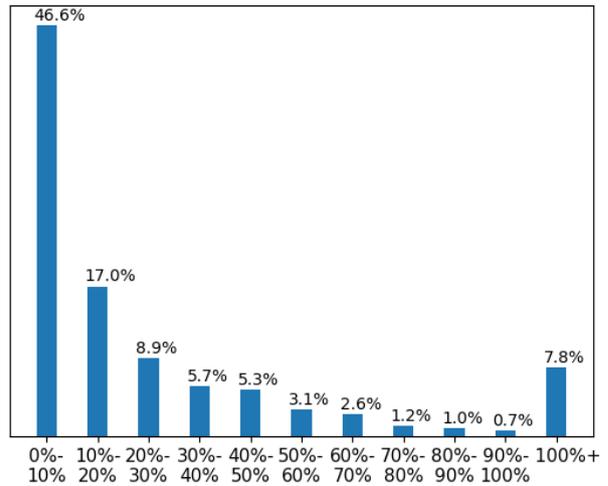


圖4. AE與真實值之比值

行分支故只有總合之結果；SKL with M.T. 則使用 model tree 且各分支進行相同迴歸預測 (scikit-learn 的 linear regression) 並將其結果以各分支判例數量加權計算總和結果；本文模型則為使用 model tree 但各分支皆不同預測方式 (詳見本文 9.1 到 9.3 段落)，再以各分支判例數量加權計算總和結果，所有預測模型皆以 8 比 2 進行分割，並採 1000 次隨機 split 實驗結果之 MAE 平均，再將三者進行比較，其 MAE 比較結果如下表所示 (表 5)。

由表 5 可見，從整體的 MAE 比較可看出不使用 model tree (即 Only SKL LinearRegs.) 與使用 model tree (即 SKL with M.T.)，相比後者有較好的表現；且單純使用 model tree (即 SKL with M.T.) 與針對不同區塊使用對應之預測方式及調整 (即本文模型)，本文模型的結果也較前者優秀。

圖 4 則展現我們提出的模型預測值與真實答案誤差之比值統計，可看出超過六成可以控制在 20% 以內。

10 實驗總結

關於准駁預測模型部分，針對所選之比較模型與前處理仍有以下可改良之部份：

對於 TF-IDF 應可增加對於相似詞進行統一化之前處理，以避免不同詞頻之近似字詞導致不同向量結果，進而影響准駁預測之可能。而對於 SBERT 模型，由於採用句向量，可能抹平主張之特徵段落而導致預測與模型學習不易，因此，採用 SBERT 搭配 LSTM 及

SBERT 加權平均當作深度學習之代表，並得出「TF-IDF 搭配 logistic regression 會較 SBERT 轉換向量來得好」此一結論或有不夠周全之處。

關於金額預測模型部分，我們採用盡可能客觀且常見之特徵，如：行政院主計處公告之當地月均消、相對人年度申報所得、聲請人是否曾家暴相對人等，以期能在有限且僅裁判書所提之特徵 (8 個主要特徵與 8 個輔助特徵) 亦不過擬合 (overfit) 的前提下進行訓練與預測，但仍有以下考量不足之處：

本實驗將所有相對人之扶養金額進行加總預測，而非針對個別相對人進行預測，因此無法在相對人為複數且扶養義務不盡相同時進行準確預測。關於金額預測模型中第三層部分，盡可能採用較為通用而直觀之輔助特徵，如：聲請人是否曾家暴相對人等 (表 4. A1 到 A4 部分)，但為了不造成過擬合亦可能有缺漏之輔助特徵，故儘管成效較僅使用 linear regression 之結果佳，不過仍有進步空間。

11 結語

儘管如上段所言，兩模型於設計或結果上仍有缺漏亦可進步之處，但我們仍望提供未來請求扶養費案件中之兩造乃至法官一客觀參考基準，或能在不久之將來對於相關輔助應用有所貢獻。

致謝

本研究承國科會研究計畫 107-2221-E-004-009-MY3 與 110-2221-E-004-008-MY3 與國立政治大學高教深耕校內補助計畫 111H124D-13 之部分補助，謹此致謝。

參考文獻

Jim-How Ho. 2021. AI 引入民事程序可行性之研究 (The feasibility research on introducing artificial intelligence into civil procedures) [In Chinese]. Doctoral Dissertation, Department of Information Management, National Taiwan University of Science and Technology. <https://hdl.handle.net/11296/pkvh27>.

黃詩淳和邵軒磊. 2020. 以人工智慧讀取親權酌定裁判文本：自然語言與文字探勘之實踐. 臺大法學論叢 *NTULawJournal*, 49 (1): 196-218.

黃詩淳. 2022. 老親扶養費酌定裁判之實證研究. 臺灣大學數位智能法院、法律科技與接近正義研討會.

林玠鋒. 2015. 論家事財產法上法院之裁量調控 - 以扶養費、家庭生活費用及贍養費之酌付為中心 (Regulation of the Judicial Discretion in Domestic Property Law : Focusing on the Determination of Maintenance, Living Expenses of the Household, and Alimony) [In Chinese]. 國立政治大學法律學系所. <https://thesis.lib.nccu.edu.tw/cgi-bin/gs32/gsweb.cgi?o=dallcdr&s=id=%22G0096651501%22.&searchmode=basic#XXXX>.

Wan-Chen Lin, Tsung-Ting Kuo, Tung-Jia Chang, Chueh-An Yen, Chao-Ju Chen, and Shou-de Lin. 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 (Exploiting Machine Learning Models for Chinese Legal Documents Labeling, Case Classification, and Sentencing Prediction)[In Chinese]. In *Proceedings of the 24th Conference on Computational Linguistics and Speech Processing (ROCLING 2012)*, pages 140–141. <https://aclanthology.org/O12-1013/>.

Donato Malerba, Floriana Esposito, Michelangelo Ceci and Annalisa Appice. 2004. Top-down induction of model trees with regression and splitting nodes. In *IEEE Transactions on Pattern Analysis and Machine Intelligence (Volume: 26, Issue: 5, May 2004)*. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1273937&isnumber=28505>.

Fabrice Muhlenbach, Long Nguyen Phuoc and Isabelle Sayn. 2020. Predicting Court Decisions for Alimony: Avoiding Extra-legal Factors in Decision made by Judges and Not Understandable AI Models. [arXiv:2007.04824](https://arxiv.org/abs/2007.04824).

Nils Reimers, Iryna Gurevych. 2019. Sentence-BERT: Sentence Embeddings using Siamese BERT-Network. [arXiv:1908.10084](https://arxiv.org/abs/1908.10084).