



AI 資料收集個案研究

如何在一週內收集 28,000 筆資料

1 週
交付時間

8,000
額外交付的資料集數目

28,000
交付的影像數目

面臨的挑戰

Lionbridge 的客戶需要在非常緊迫的時程內，取得大量的資料為他們的 AI 模型進行物件辨識訓練。客戶要求要在數天內取得約 20,000 個影像，而且是高品質的人類資料，而非合成影像 (後者的品質往往太低，可能會導致模型效能明顯低落)。客戶尤其指定他們需要的是物件中還有物件的影像，這會有助 AI 模型學習辨識那些呈現位於其他物件中的物件影像，像是籃子、包包、碗，諸如此類。他們要求一個資料集內要有四種影像：

- 各個物件各自的影像
- 一個物件在另一個物件中的影像
- 不含任何物件的空背景影像

另外值得注意的是，客戶也以來自不同觀點的資料為優先。以同一類物品的 20,000 張影像訓練模型，當然比不上以 20,000 張不同影像進行訓練的結果。從全球各地許多不同人口組成的參加者取得的影像，亦會有助模型理解資料，進而為所有人口組成的受眾提供更好的服務。

來自不同國家/地區、年齡層、性別等的人們，往往能為客戶網站帶來許多不同種類的影像。而以更多元的資料集來訓練網站的模型，也就能夠為更廣泛的客群服務。

客戶簡介

Lionbridge AI™ 協助的這個客戶，是間媒合品牌與其專案所需之創意專業人才的公司。

該公司設置並營運一個創新的平台，協助創意人才與需要創意人才執行專案的品牌搭上線。創意人才可以刊登他們的作品集並設定條件以供搜尋；品牌方則可張貼工作或專案摘要。總的來說，這個 Lionbridge 客戶致力於促進品牌與創意人才間的聯繫與交流，雙方可以透過他們的平台聯絡，為目前或日後的專案建立合作關係。



我們眾包服務的一些統計數據



使用的語言超過 **350** 種



居住在遍佈全球超過 **450** 個地點

- › 北美：**26%**
- › 歐洲：**29.5%**
- › 亞洲：**27%**
- › 非洲：**6.5%**
- › 南美：**8.5%**
- › 大洋洲/澳洲：**2.5%**



- › 女性：**52%**
- › 男性：**48%**



年齡層：**18 到 60 歲以上**

從事的產業：

- › **16%** 商業
- › **16%** 工程
- › **15%** 人文
- › **13%** 科學
- › **9%** 技術
- › **4%** 電子商務
- › **2%** 人力資源 (HR)
- › **2%** 醫療保健
- › **2%** 藝術
- › **2%** 法律
- › **10%** 其他

解決方案

為了服務這個客戶，我們使用了自有的 Lionbridge Aurora AI Studio™ 平台。透過這個平台，我們能與五十多萬遍佈全球各地、組成多元的眾包人才聯繫。這些人才無論在地點、使用的語言、年齡、性別以及從事的產業等方面都非常多元。我們會邀請他們一同合作，進而以前所未見的速度完成包括資料收集等許多工作。

針對這個專案，我們在 Aurora AI Studio 中為客戶建立了工作，並在數小時內吸引了超過 2,000 名參加者加入。參加者們有八個小時的時間完成資料收集工作。同一時間，我們亦建置了規模較大的內部品管團隊來審閱這些資料。之所以要建立較為大型的團隊，是因為資料量龐大同時專案時程又非常緊迫。這個團隊審閱了我們收集到的資料，確認它們正確無誤並符合客戶的需求。完成品質審閱後，我們也為每個影像命名其中繼資料，替客戶節省了許多小時的人力。

Lionbridge 將收集到的資料分三個批次交付給客戶。我們提早將第一批資料集交付給客戶，以便他們能盡快開始訓練模型。這一批資料含有三天內收集到的 12,000 個影像。第二批則是在五天內交付，內含剩餘的 8,000 個影像。

由於客戶對收集到的這兩批 AI 訓練資料非常滿意，因此又要求我們再以兩天的時間額外提供 8,000 個影像。我們欣然從命，總共交付了 28,000 個影像給客戶，而且在短短一週內全數完成。最初所要求的 20,000 個影像，則只花了四天就完成交付。

方法

Lionbridge 採用了由多個步驟組成的流程來支援客戶：

- 步驟 1：在 Aurora AI Studio 中建立工作
- 步驟 2：吸引參加者加入
- 步驟 3：接受收集到的資料
- 步驟 4：審閱資料並命名其中繼資料
- 步驟 5：將收集到的資料交付給客戶
- 步驟 6：根據客戶的要求，收集並交付更多資料





—○ 成果

Lionbridge AI 主要是以三個方法來協助這個客戶。首先，運用我們的 Aurora AI Studio 平台以及極為多元的眾包人才，我們累積了非常大量由人類收集、能反映全球各地之觀點和影像的高品質資料。這麼做可確保客戶能避免完全仰賴合成資料所導致的後果，因為這可能會進一步造成模型訓練成效不佳。Lionbridge 甚至籌組了規模較大的品管團隊，驗證過資料後再進行交付。這些無可挑剔的資料將可協助客戶訓練其模型，進而能熟練順暢地提供品牌及創意人才所需的支援，不會受限於所在地點、人口組成或作品集的內容。

我們協助客戶的第二個方法，是在一週內便交付了非常大量的資料（事實上甚至比客戶原本要求的數量還多）。快速的交付時程對訓練模型而言非常重要，因為每多耽誤一天都得付出高昂的代價。Lionbridge 運用自有的 Aurora AI Studio 平台極其快速地完成這個專案，使客戶得以在人力以及業務損失成本上省下數千美元。他們亦可確保自己平台的模型能在短短一週內便獲得足夠的訓練。

我們讓客戶大感驚艷的第三個方法，就是提供超越他們最初要求的服務。客戶原本要求 20,000 個影像，我們最終取得了 28,000 個。Lionbridge 對此深感自豪，因為我們不但提供了客戶所需的資料，更交付了他們原本沒意識到會想要的資料。能夠在短短一週內，滿足客戶所需的一切甚至更多，著實是很大的成就。



如需深入了解，歡迎造訪
LIONBRIDGE.COM