
前言

歡迎閱讀《從程式員到 AI 專家》，我在好幾年前就想要寫這本書了，但是直到機器學習（ML）和（尤其是）TensorFlow 最近的進展，我才能將這個想法付諸實踐。本書的目的是幫你這位程式員做好準備，讓你有能力面對許多機器學習場景，你不需要取得博士學位就可以成為一位 ML 和 AI 開發者！希望你以後會覺得這是一本有用的書，它將讓你充滿信心，開始這趟美妙且滿載而歸的旅程。

誰該閱讀本書？

如果你對 AI 和 ML 有興趣，而且想要快速地建立一個能夠從資料中學習的模型，那麼這本書就很適合你。如果你想要從常見的 AI 和 ML 概念學起（電腦視覺、自然語言處理、序列建模…等），而且想要知道如何訓練神經模型來解決這些領域的問題，我認為你會喜歡這本書。如果你已經訓練過模型，而且想要透過手機、瀏覽器或雲端來讓用戶使用，本書也是為你而寫的！

最重要的是，如果你因為覺得困難，而一直猶豫是否該踏入這個有價值的電腦科學領域，尤其是你認為你必須重拾塵封已久的微積分書本，別怕，本書採取程式優先的做法，讓你知道使用 Python 和 TensorFlow 來踏入機器學習和人工智慧的大門有多麼簡單。

著作動機

我是在 1992 年春天開始認真地從事人工智慧的，當時我剛取得物理學學位，住在倫敦，遭遇可怕的經濟困境，有 6 個月找不到工作。那時英國政府啟動一項專案，準備訓練 20 位 AI 技術人才，開始接受應徵申請。我是第一個被錄取的，經過三個月之後，這項專案以失敗告終，因為儘管在理論上，AI 可以完成大量的工作，我們卻無法用簡單的方法來實踐它。當時，我可以用 Prolog 語言來撰寫簡單的推理程式，並且用 Lisp 語言來執行串列處理，但沒有人知道如何在業界部署它們，然後，我進入著名的「AI 寒冬」。

2016 年，當我在 Google 參與 Firebase 專案時，Google 為所有工程師提供了機器學習訓練，當時我們一起坐在一間房間裡，聽著關於微積分和梯度下降的講座，我根本無法把那些東西與 ML 的實作聯繫起來，這讓我想到 1992 年的場景，我把這個感受，以及我們應該如何教育 ML 人才的想法回饋給 TensorFlow 團隊，他們在 2017 年錄取我。隨著 TensorFlow 2.0 在 2018 年發表，特別是它的重心是可以讓開發者更容易入門的高階 API，我認為必須用一本書來教大眾利用它使用 ML，免得只有數學家或博士能夠使用 ML。

我相信，有越多人使用這項技術，並且部署它來讓終端用戶使用，就會大幅增加 AI 與 ML 的數量，從而避免另一次 AI 寒冬的降臨，並且讓世界更加美好。我已經看到它的影響了，包括 Google 的糖尿病視網膜病變研究、賓洲立大學與 PlantVillage 建構了一個行動 ML 模型來協助農夫診斷木薯病、無國界醫生組織使用 TensorFlow 模型來協助診斷斷抗生素抗藥性，族繁不及備載！

本書簡介

本書有兩大部分。第一部分（第 1–11 章）討論如何在各種場景之下使用 TensorFlow 來建構機器學習模型，它將帶你從第一原理（用只有一個神經元的神經網路來建構模型）經歷電腦視覺、自然語言處理，以及序列建模。接下來的第二部分（第 12–20 章）將協助你將模型植入別人手裡的 Android 和 iOS、用 JavaScript 植到瀏覽器，以及透過雲端提供服務。大多數的章節都是互相獨立的，所以你可以跳到各章來學習新知識，當然，你也可以從頭到尾看完這本書。

你需要了解的技術

本書前半部分的目標是協助你學習如何使用 TensorFlow 來以各種架構建立模型，唯一的先決條件是了解 Python，尤其是 Python 的資料表示法和陣列處理法。你可能也要了解 NumPy，它是進行數值計算的 Python 程式庫。如果你不熟悉它們，它們都很容易學習，你應該可以在過程中認識它們（不過有些陣列標示法或許比較難以掌握）。

在第二部分中，我通常不會教導語言知識，而是展示如何在各種語言裡面使用 TensorFlow 模型。因此，舉例來說，在介紹 Android 的那一章（第 13 章），你將學會如何以 Kotlin 和 Android studio 來建構 app，在介紹 iOS 的那一章（第 14 章），你將學會用 Swift 和 Xcode 來建構 app。我不會教導這些語言的語法，所以如果你不熟悉它們，你可能需要閱讀入門教材，由 Jonathon Manning、Paris Buttfield-Addison 和 Tim Nugent 合著的 *Learning Swift* (O'Reilly) 是很棒的選擇，繁體中文版《Swift 學習手冊》由碁峰資訊出版。

線上資源

本書使用和提供各種線上資源，建議你至少關注一下 TensorFlow (<https://www.tensorflow.org>) 和它的 YouTube 頻道 (<https://www.youtube.com/tensorflow>)，來了解本書談到的技術有沒有任何更新和重大變化。

本書的程式碼位於 <https://github.com/lmoroney/tfbook>，我會隨著平台的演進而持續更新它。

本書編排慣例

本書使用下列的編排規則：

斜體字 (*Italic*)

代表新術語、URL、email 地址、檔名，與副檔名。中文以楷體表示。

定寬字 (Constant width)

在長程式中使用，或是在文章中代表變數、函式名稱、資料庫、資料型態、環境變數、陳述式、關鍵字等程式元素。

TensorFlow 簡介

若要製作人工智慧（AI），機器學習（ML）與深度學習是很棒的起點，但是，在初期，一般人很容易被所有的選項和新術語搞得不知所措，本書希望為程式員揭開神秘的面紗，帶領你藉著編寫程式來實作機器學習和深度學習的概念，並且在電腦視覺、自然語言處理（NLP）及其他場景中，建立出展現類似人類行為的模型，因此，它們是一種合成的，或人工的智慧。

但是我們說的機器學習究竟是什麼東西？在深入討論之前，我們先從程式員的角度來了解它，然後，本章將告訴你如何安裝業界的工具，包括 TensorFlow 本身，以及寫程式和除錯 TensorFlow 模型的環境。

什麼是機器學習？

在了解 ML 的來龍去脈之前，我們先從傳統程式設計的角度來看看它是如何演變的。我們先討論什麼是傳統程式設計，然後想一下它在哪些情況之下能力有限。接下來，我們會了解為了處理這些案例，ML 是如何進化並且開啟實作新場景的新機會，從而解鎖許多人工智慧的概念。

傳統的程式設計需要編寫規則，用程式語言來表達規則，讓它處理資料並提供答案。幾乎所有可以用程式來編寫的東西都是如此。

例如，受歡迎的打磚塊遊戲用程式碼來決定球的移動方向、分數，以及贏得或輸掉遊戲的各種條件，想一下球從磚塊反彈的情況，如圖 1-1 所示。

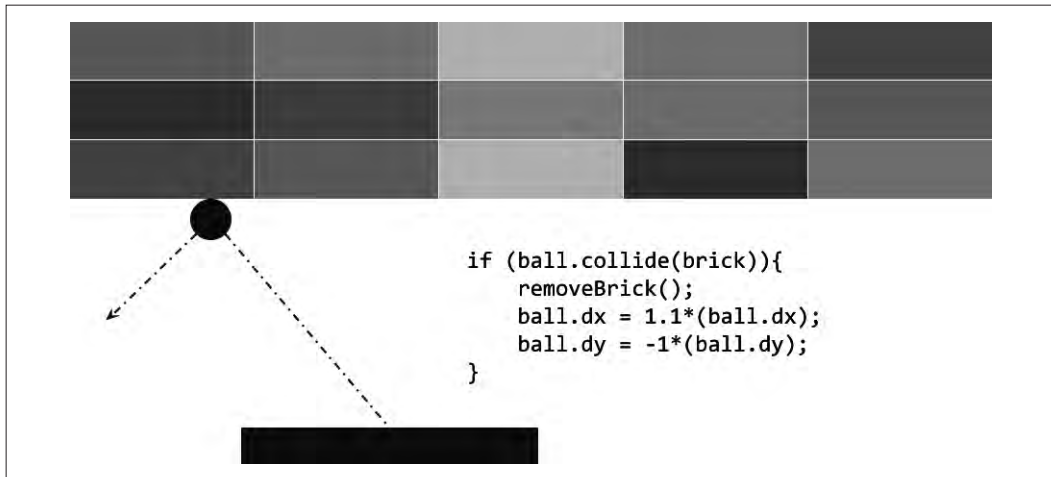


圖 1-1 打磚塊遊戲的程式

球的移動方向可以用它的 `dx` 與 `dy` 屬性來決定，當它打到磚塊時，磚塊會被移除，球的速度會增加，方向也會改變，這段程式根據與遊戲情況有關的資料採取行動。

舉另一個例子——金融服務場景。你有關於公司股票的資料，例如它的現價和目前盈餘，你可以用圖 1-2 的程式來計算一個稱為 P/E（市價除以每股盈餘）的比率。

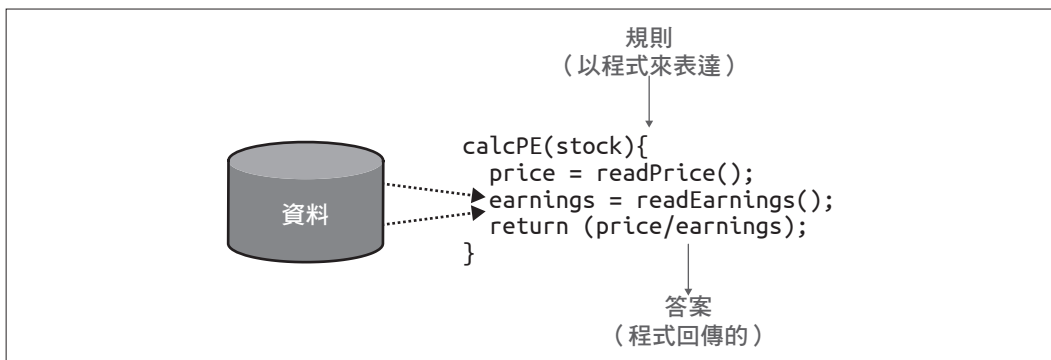


圖 1-2 金融服務場景的程式碼

你的程式會讀取價格，讀取盈餘，然後回傳一個前者除以後者的值。

如果我試著用一張圖表來總結這種傳統程式，它應該會類似圖 1-3。

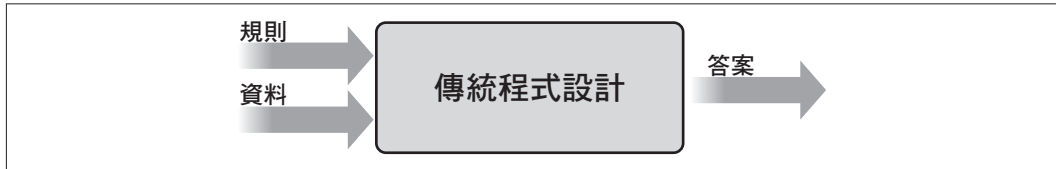


圖 1-3 傳統程式設計的高階視角

如你所見，我們用程式語言來描述規則，用這些規則來處理資料，結果就是答案。

傳統程式設計的限制

圖 1-3 的模式從最初就是開發的主幹，但是它有一個固有的限制：只能處理可以找出規則的場景。其他的場景呢？通常因為程式會過於複雜，所以不可能開發出來，根本無法用程式來處理。

例如，考慮偵測活動的情況。可以偵測活動的健康監視器是最近出現的一項創新，之所以直到最近才出現，不僅因為它價格低廉、體積很小，也因為進行偵測的演算法以前根本寫不出來，我們來研究一下原因。

圖 1-4 是簡單的偵測走路的活動演算法，透過人的移動速度來偵測，如果它少於某個值，我們就可以認為他們應該在走路。




圖 1-4 偵測活動的演算法

因為我們的資料是速度，我們可以擴展程式，來偵測他們是不是在跑步（圖 1-5）。



圖 1-5 擴展演算法來偵測跑步

如你所見，我們可以藉著判斷速度低於某個值（假如是 4 英里）來認出用戶在走路，否則他就是在跑步。這在某方面來說是可行的。

假設我們要將這段程式擴展成另一種流行的健身運動——騎單車，演算法如圖 1-6 所示。

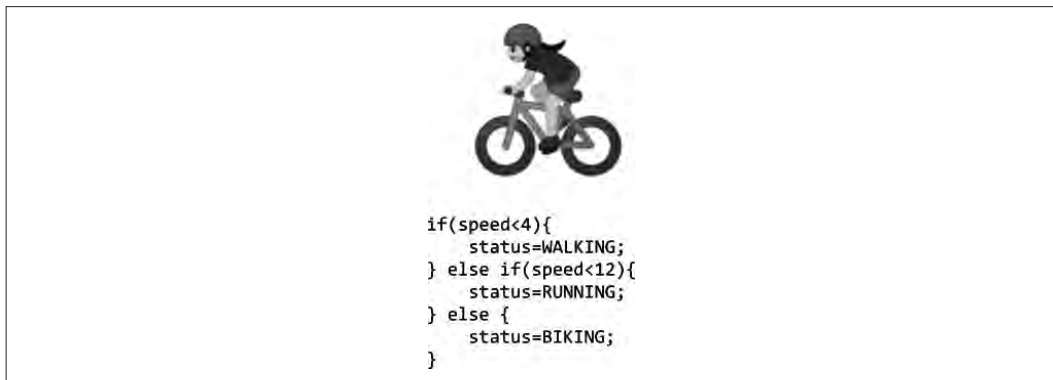


圖 1-6 擴展演算法來偵測騎單車

在這裡只偵測速度實在太草率了，舉例來說，有些人跑得比別人快，而且往下坡跑步可能比往上坡騎單車更快。但是整體來說，這種做法仍然可行。然而，如果我們想要實作另一個場景，例如打高爾夫球時，會怎樣（圖 1-7）？



圖 1-7 如果要編寫高爾夫演算法呢？

現在我們卡住了，我們該如何用這種方法來判斷用戶正在打高爾夫？那個人可能會走路一段時間，停下來，做一些動作，再走路一段時間，但是我們怎麼知道他在打高爾夫？

用傳統規則來偵測活動的做法遇到瓶頸了。但是或許有更好的方法。

也就是踏入機器學習大門。

從編寫程式到學習

回顧一下之前那張展示傳統程式設計的圖（圖 1-8），它用一些規則來處理資料，並產生答案。在活動偵測場景中，資料是人移動的速度，據此，我們可以編寫規則，來偵測他們的活動究竟是走路、騎單車，還是跑步。但是在偵測打高爾夫球時，我們遇到瓶頸，因為我們沒辦法用規則來判斷那個活動的樣貌。

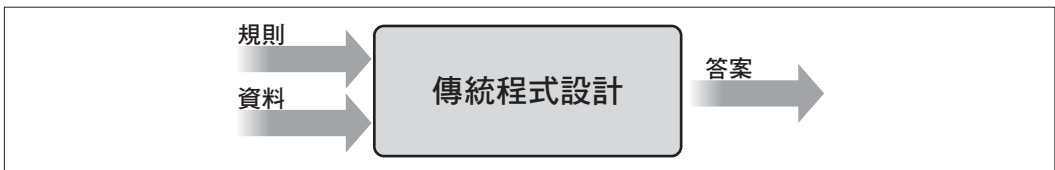


圖 1-8 傳統程式設計流程

但是，如果把這張圖左右對調呢？我們不找出規則，而是找出答案，並且結合資料來尋找規則，那會怎樣？

圖 1-9 就是這種做法，我們可以用這張高階的圖來定義機器學習。



圖 1-9 藉由左右對調來產生機器學習

那麼，這張圖是什麼意思？現在不是由我們試圖找出規則是什麼，而是取得許多關於場景的資料，標注那些資料，由電腦找出為一項資料指定某個標籤，為另一項資料指定另一個標籤的規則。

在活動偵測場景中，如何採取這種做法？我們可以用感應器來取得關於用戶的資料，如果讓他們使用穿戴式設備，該設備可以偵測心跳率、位置、速度等資訊，並且在他們進行各種活動時，收集這類的資料，我們就有代表「走路的樣子」、「跑步的樣子」等資料（圖 1-10）。

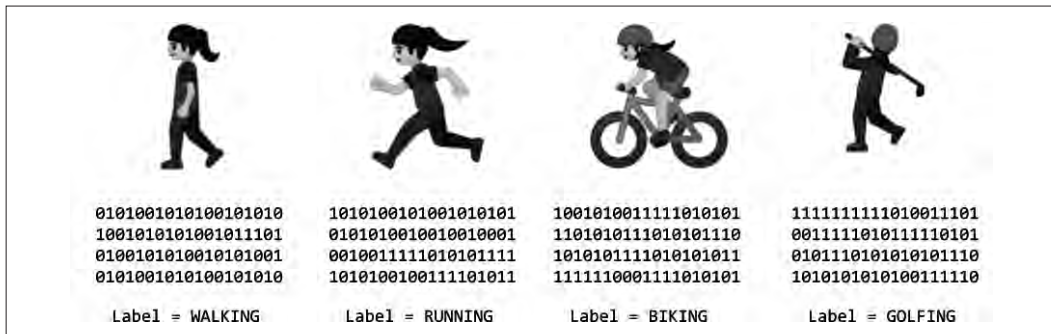


圖 1-10 從寫程式到 ML：收集和標注資料

現在程式員的工作從「找出規則」變成「確認活動」，以及寫出為資料指定標籤的程式。如果我們可以做到，我們就可以擴展原本以程式碼來實作的場景，機器學習就是做這件事的技術，但是我們需要一種框架才能開始工作，這就是為什麼要用 TensorFlow。下一節要介紹它是什麼，以及如何安裝它，在本章稍後，你將開始編寫你的第一個程式，用它來學習兩個值之間的模式，就像上述的場景那樣。它是個簡單的「Hello World」場景，但是它的基本設計模式與非常複雜的場景時所使用的一樣。

人工智慧領域既龐大且複雜，涵蓋讓電腦像人類一樣思考和行動的所有事物。人類會透過範例來學習新行為，因此，機器學習可以視為人工智慧開發的入口，透過它，機器可以學會像人類一樣看東西（一種稱為電腦視覺的領域）、讀取文本（text）（自然語言處理），以及其他能力。本書將使用 TensorFlow 框架來討論機器學習的基本概念。

什麼是 TensorFlow ？

TensorFlow 是一個開源平台，可讓你建立機器學習模型和使用它。它實作了許多機器學習常用的演算法和模式，讓你不必學習底層的數學和邏輯即可直接專注於你的場景。它希望讓所有人使用，包括業餘愛好者、專業開發者，以及將人工智慧的界限往外擴展的研究員。更重要的是，它也可以讓你將模型部署到 web、雲端、行動設備，及嵌入式系統。本書將探討以上所有的場景。

圖 1-11 是 TensorFlow 的高階架構。

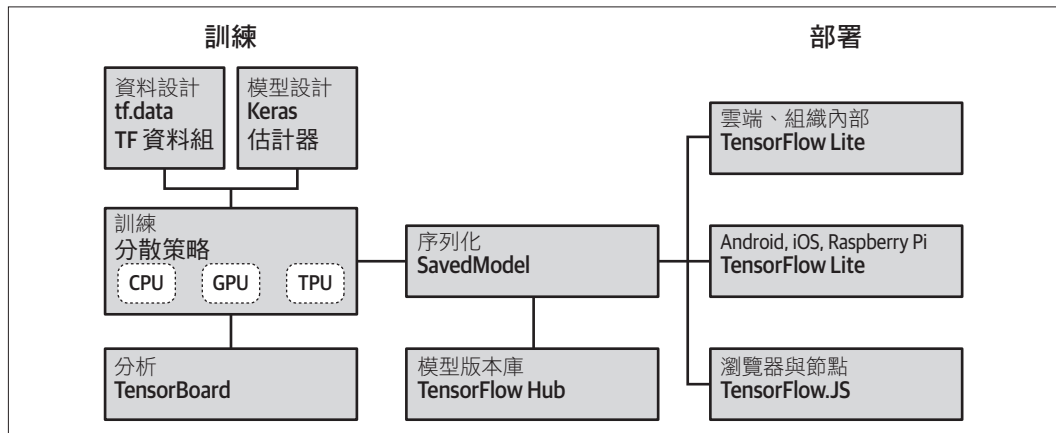


圖 1-11 TensorFlow 的高階架構

建立機器學習模型的程序稱為**訓練**，在這個程序中，電腦使用一組演算法來了解輸入，以及如何區分它們。因此，舉例來說，如果你想要讓電腦辨識貓與狗，你可以使用牠們的許多照片來建立一個模型，電腦會用那個模型來學習貓為什麼是貓，狗為什麼是狗。訓練好模型之後，用它來辨識未來的輸入或對輸入進行分類稱為**推理**（*inference*）。

為了訓練模型，你必須提供一些東西，第一種是一組用來設計模型的 API。在 TensorFlow 中，你可以採取三種主要的做法：你可以自己編寫所有的程式，自己想出如何讓電腦進行學習的邏輯，並且用程式來實作它（不建議）；你也可以使用內建的估計器（*estimator*），它們是現成的神經網路，而且你可以自訂它們；或者，你可以使用 Keras，Keras 是一種高階的 API，可讓你將常見的機器學習範式（*paradigms*）封裝在程式碼裡面。本書的重點是使用 Keras API 來建立模型。

訓練模型的方法有很多種，在多數情況下，你應該只有一顆晶片，可能是中央處理單元（CPU）、圖形處理單元（GPU），或是一種稱為張量處理單元（TPU）的新晶片。比較高級的工作環境與研究環境可能要在多顆晶片上執行平行訓練，採取分散策略，將訓練分給多顆晶片，TensorFlow 也支援這種技術。

資料是任何模型的命脈，如前所述，如果你想要製作一個可以辨識貓與狗的模型，你就要用許多貓與狗的樣本來訓練它。但是該如何管理這些樣本？你將會漸漸看到，做這件事需要編寫的程式碼通常比建立模型本身更多。TensorFlow 有一些簡化這個過程的 API，稱為 TensorFlow Data Services。它們有許多預先處理過的資料組可供學習，你可以用一行程式碼來使用它們，它們也有一些工具可以處理原始資料，讓它更容易使用。

除了建立模型之外，你也要在它們可以供人使用時，把它們送到人們的手裡。為此，TensorFlow 有一些伺服 API，你可以透過 HTTP 連結提供推理結果給雲端或 web 用戶。如果你打算在行動或嵌入式系統上運行模型，你可以使用 TensorFlow Lite，它提供一組工具，可以在 Android、iOS，以及 Raspberry Pi 之類的 Linux 嵌入式系統上進行模型推理。TensorFlow Lite 的分支 TensorFlow Lite Micro（TFLM）也可以透過一種稱為 TinyML 的新概念在微控制器上提供推理。最後，如果你想要讓瀏覽器或 Node.js 的用戶使用模型，TensorFlow.js 可讓你用這種方式來訓練和執行模型。

接下來，我們將告訴你如何安裝 TensorFlow，讓你可以開始用它來建立和使用 ML 模型。

使用 TensorFlow

這一節將介紹三種安裝和使用 TensorFlow 的方法。我們會先討論如何使用命令列來將它安裝到你的開發工具箱裡面，接下來討論如何使用流行的 PyCharm IDE（整合開發環境）來安裝 TensorFlow，最後介紹 Google Colab，以及如何在你的瀏覽器使用雲端後端來讀取 TensorFlow 程式碼。

在 Python 裡安裝 TensorFlow

TensorFlow 可讓你用多種語言來建立模型，包括 Python、Swift、Java...等，本書把重心放在 Python 上，由於 Python 廣泛支援數學模型，所以它是事實上的機器學習語言，如果你還沒有安裝它，我強烈建議你造訪 Python (<https://www.python.org>) 來安裝並執行它，並且造訪 [learnpython.org](https://www.learnpython.org) (<https://www.learnpython.org>) 來學習 Python 語法。

使用 Python 時，安裝框架的方法有很多種，TensorFlow 團隊預設支援的是 pip。

因此，在 Python 環境安裝 TensorFlow 很簡單，只要使用：

```
pip install tensorflow
```

注意，從第 2.1 版開始，它預設安裝 GPU 版的 TensorFlow，在這個版本之前，它使用 CPU 版本。因此，在安裝前，請確保你有支援它的 GPU，及其所有必要的驅動程式，詳情見 TensorFlow (<https://oreil.ly/5upaL>)。

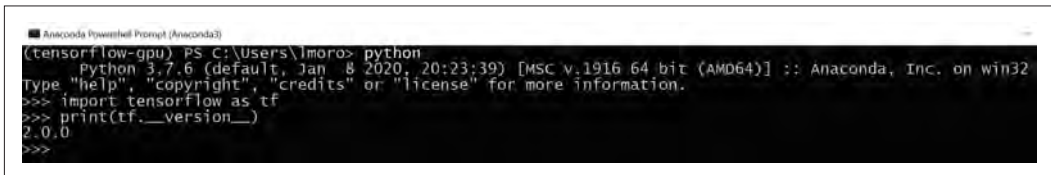
如果你沒有所需的 GPU 或驅動程式，你仍然可以在任何 Linux、PC 或 Mac 上，用這個命令來安裝 CPU 版的 TensorFlow：

```
pip install tensorflow-cpu
```

你可以在啟動並運行之後，用下列程式來測試你的 TensorFlow 版本：

```
import tensorflow as tf
print(tf.__version__)
```

你應該可以看到類似圖 1-12 所示的輸出。它會印出目前正在執行的 TensorFlow 版本，圖中安裝的是 2.0.0 版。



```
(tensorflow-gpu) PS C:\Users\lmoro> python
Python 3.7.6 (default, Jan 8 2020, 20:23:39) [MSC v.1916 64 bit (AMD64)] :: Anaconda, Inc. on win32
Type "help", "copyright", "credits" or "license()" for more information.
>>> import tensorflow as tf
>>> print(tf.__version__)
2.0.0
>>>
```

圖 1-12 在 Python 中執行 TensorFlow

在 PyCharm 中使用 TensorFlow

我特別喜歡用免費社群版的 PyCharm (<https://www.jetbrains.com/pycharm>) 來以 TensorFlow 建構模型。PyCharm 好用的地方很多，我最喜歡的一種是它可讓我輕鬆地管理虛擬環境，這代表我可以在多個 Python 環境中使用專案專屬的工具版本，例如 TensorFlow，舉例來說，如果你想要在一項專案中使用 TensorFlow 2.0，在另一項專案中使用 TensorFlow 2.1，你可以用虛擬環境來分隔它們，如此一來，當你在這些專案之間切換時，不需要安裝 / 移除依賴項目。此外，使用 PyCharm 可以為 Python 程式進行步進除錯，這是必備的功能，尤其當你是新手時。

例如，在圖 1-13 中，有一個稱為 *example1* 的新專案，並且指定以 Conda 建立一個新環境。當我建立專案時，我會得到一個乾淨且全新的虛擬 Python 環境，可在裡面安裝任何想要的 TensorFlow 版本。



圖 1-13 用 PyCharm 建立新的虛擬環境

建立專案之後，你可以打開 File → Settings 對話框，在左邊的選單選擇「Project: <你的專案名稱>」，你會看到改變 Project Interpreter 與 Project Structure 的設定選項，選擇 Project Interpreter 會顯示你正在使用的 interpreter，以及一些已被安裝在這個虛擬環境裡面的程式包（圖 1-14）。

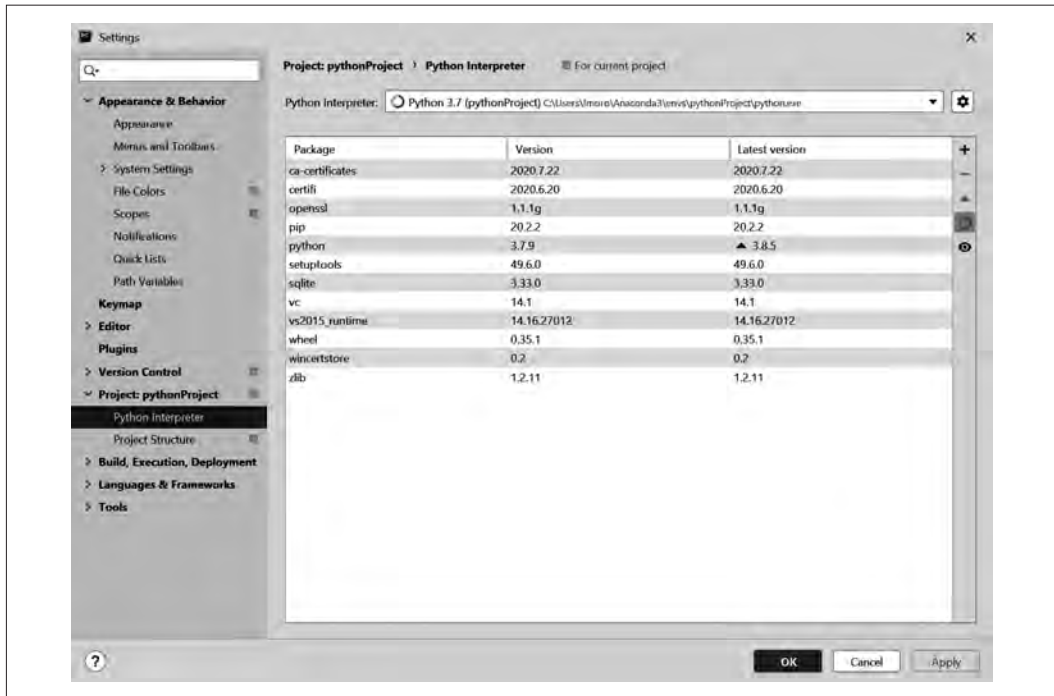


圖 1-14 將程式包加入虛擬環境

按下右邊的 + 按鈕會出現一個對話框，顯示目前可用的程式包。在搜尋框裡輸入「tensorflow」會顯示名稱有「tensorflow」的所有程式包（圖 1-15）。




圖 1-15 用 PyCharm 安裝 TensorFlow

選擇 TensorFlow 或你想要安裝的任何其他程式包之後，按下 Install Package 按鈕，PyCharm 將完成其餘的工作。

安裝 TensorFlow 之後，你就可以在 Python 裡面編寫 TensorFlow 程式碼和對它進行 debug 了。

在 Google Colab 裡使用 TensorFlow

另一個選項是使用 Google Colab (<https://colab.research.google.com>)，這應該是最容易上手的，它是代管的 Python 環境，你可以透過瀏覽器來使用它。Colab 真正的優點在於它提供 GPU 和 TPU 後端，所以你可以免費使用最先進的硬體來訓練模型。

當你造訪 Colab 網站時，你會看到打開 Colabs 或啟動新 notebook 的選項，如圖 1-16 所示。

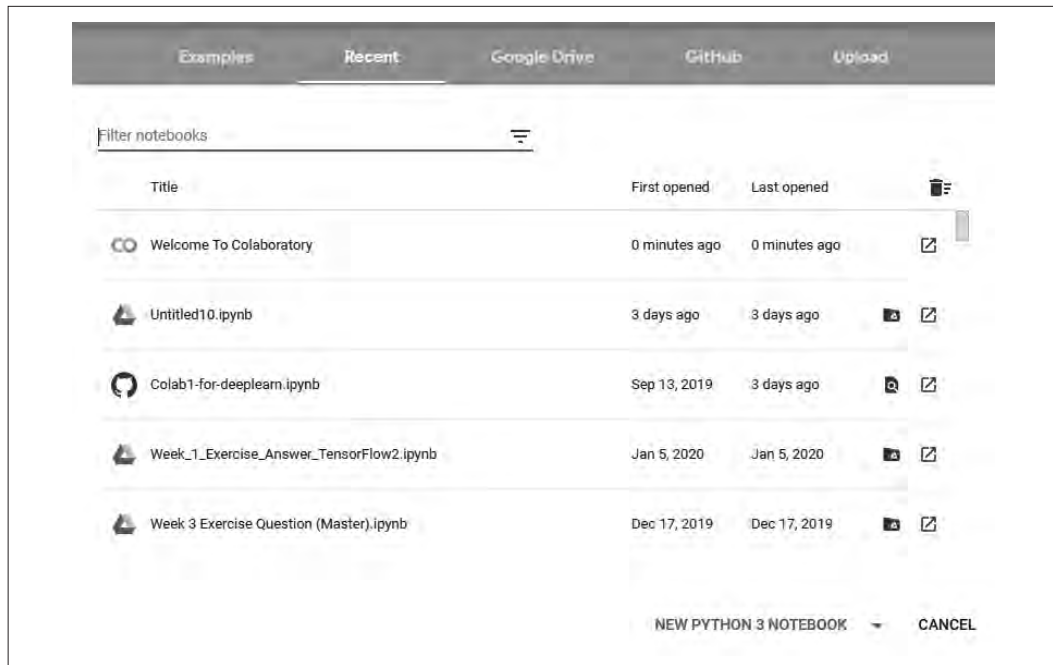


圖 1-16 使用 Google Colab 來工作

按下 New Python 3 Notebook 連結可開啟一個編輯器，你可以在那裡加入程式碼或文字的窗格（圖 1-17），你可以按下窗格左邊的 Play 按鈕（箭頭形狀）來執行程式碼。



圖 1-17 在 Colab 裡執行 TensorFlow 程式碼

像圖中那樣檢查 TensorFlow 版本是必要的，以確保你正在執行正確的版本。Colab 內建的 TensorFlow 通常會落後一到兩個版本，若是如此，你可以用 `pip install` 來更新它如下：

```
!pip install tensorflow==2.1.0
```

當你執行這個命令之後，Colab 環境就會使用你指定的 TensorFlow 版本。

開始進行機器學習

正如我們在本章稍早看到的，機器學習的範式就是取得資料，標注那些資料，並且找出幫資料和標籤配對的規則，若要用程式來展示這個範式，下面的例子應該是最簡單的場景。考慮兩組數字：

```
X = -1, 0, 1, 2, 3, 4
Y = -3, -1, 1, 3, 5, 7
```

X 與 Y 的值有某個關係（例如，當 X 是 -1 時，Y 是 -3，當 X 是 3 時，Y 是 5，以此類推），看得出這個關係嗎？

看了幾秒之後，或許你可以看到它的模式是 $Y = 2X - 1$ ，你是怎麼知道的？每個人會用不同的方式來找出它，但我通常聽到人們發現：X 在序列裡每次都加 1，Y 每次都加 2，所以 $Y = 2X +/-$ 某個數字，接下來，他們發現當 $X = 0$ 時， $Y = -1$ ，所以答案應該是 $Y = 2X - 1$ 。他們繼續觀察其他的數字，發現這個假設是「成立」的，所以答案是 $Y = 2X - 1$ 。

這個過程很像機器學習程序，我們來看一些透過 TensorFlow 來讓神經網路來幫你解決這個問題的程式碼。

下面是完整的程式，它使用 TensorFlow Keras API。不用擔心看不懂，我會逐行講解它們：

```
import tensorflow as tf
import numpy as np
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

model = Sequential([Dense(units=1, input_shape=[1])])
model.compile(optimizer='sgd', loss='mean_squared_error')

xs = np.array([-1.0, 0.0, 1.0, 2.0, 3.0, 4.0], dtype=float)
ys = np.array([-3.0, -1.0, 1.0, 3.0, 5.0, 7.0], dtype=float)

model.fit(xs, ys, epochs=500)

print(model.predict([10.0]))
```

我們從第一行開始看起。你應該聽過神經網路，而且應該看過以互相連接的幾層神經元來解釋它們的圖，類似圖 1-18。




圖 1-18 典型的神經網路

當你看到這種神經網路時，可以將每一個「圓圈」視為一個神經元，每一排圓圈就是一個階層。所以，圖 1-18 有三層：第一層有五個神經元，第二層有四個，第三層有兩個。

回顧程式，從第一行可以看到，我們定義了最簡單的神經網路，它只有一層，而且裡面只有一個神經元：

```
model = Sequential([Dense(units=1, input_shape=[1])])
```

在使用 TensorFlow 時，你可以用 `Sequential` 來定義階層，在 `Sequential` 裡面，你可以設定每一層的樣子，在 `Sequential` 裡面只有一行，所以我們只有一層。

然後，你可以用 `keras.layers` API 來定義那一層的長相。神經層有許多不同的類型，我們在這裡使用 `Dense` 層。「`Dense`」代表一組完全（或稠密地（`densely`））互連的神經元，就像圖 1-18 那樣，每一個神經元都與下一層的每一個神經元連接，它是最常見的神經層類型。我們的 `Dense` 層使用 `units=1`，所以在整個神經網路裡，我們只有一個稠密層，裡面有一個神經元。最後，當我們在神經網路裡指定第一層時（在這個例子中，它是我們唯一的一層），我們必須告訴它輸入資料的外形（`shape`）是什麼，這個例子的輸入資料是 `X`，它只是一個值，所以我們指定這個外形。

從下一行開始很有趣，我們看一下：

```
model.compile(optimizer='sgd', loss='mean_squared_error')
```

如果你用機器學習做過任何事情，你應該知道它涉及許多數學，如果你有好幾年沒有碰微積分了，它看起來應該是入門的障礙，這一行就是開始使用數學的地方，它是機器學習的核心。

在這個場景中，電腦對於 `X` 與 `Y` 之間的關係一點概念都沒有，所以它會用猜的，假設它猜 $Y = 10X + 10$ ，接下來，它必須評估這次的猜測是好是壞，這就是損失函數的功能。

它已經知道當 `X` 是 `-1`、`0`、`1`、`2`、`3` 與 `4` 時的答案了，所以損失函數可以比較這些答案，來了解猜出來的關係對不對。如果它猜 $Y = 10X + 10$ ，那麼當 `X` 是 `-1` 時，`Y` 就是 `0`，正確的答案是 `-3`，所以有一點落差。但是當 `X` 是 `4` 時，猜出來的答案是 `50`，而正確的答案是 `7`，這就相去甚遠了。

掌握這個知識之後，電腦會猜另一次，這就是 `optimizer`（優化函數）的功能。此時就是大量使用微積分的時候。你可以為不同的場景選擇適合的優化函數，在這個例子裡，我們選擇 `sgd`，它是 *stochastic gradient descent*（隨機梯度下降）的縮寫，`sgd` 是一種複

雜的數學函數，當你將一個值（也就是之前的猜測），以及計算誤差（error，或損失，loss）的結果傳給它時，它可以產生另一個值。它的工作就是隨著時間過去將損失最小化，藉此讓猜出來的公式越來越接近正確的那一個。

接下來，我們將數字改成可讓神經層接收的資料格式，Python 有一個稱為 Numpy 的程式庫，TensorFlow 可以使用它，在這裡，我們將數字放入一個 NumPy 陣列，來方便它處理它們：

```
xs = np.array([-1.0, 0.0, 1.0, 2.0, 3.0, 4.0], dtype=float)
ys = np.array([-3.0, -1.0, 1.0, 3.0, 5.0, 7.0], dtype=float)
```

接下來，執行 `model.fit` 就可以開始進行學習程序了：

```
model.fit(xs, ys, epochs=500)
```

你可以把它想成「將 X 擬合至 Y，並嘗試 500 次」。在第一次嘗試時，電腦會猜測一個關係（也就是 $Y = 10X + 10$ 之類的東西），並估計那次猜測的好壞，然後將結果傳給優化函式，優化函式會產生另一次猜測，這個程序會不斷重複，它的邏輯在於讓損失（或誤差）隨著時間而下降，因此「猜測」的結果會越來越好。

圖 1-19 是在 Colab notebook 執行它的畫面。注意 loss 值是如何隨著時間改變的。

```
Epoch 1/500
6/6 [=====] - 9s 2s/sample - loss: 3.2868
Epoch 2/500
6/6 [=====] - 0s 652us/sample - loss: 2.7447
Epoch 3/500
6/6 [=====] - 0s 323us/sample - loss: 2.3150
Epoch 4/500
6/6 [=====] - 0s 411us/sample - loss: 1.9737
Epoch 5/500
6/6 [=====] - 0s 306us/sample - loss: 1.7021
Epoch 6/500
6/6 [=====] - 0s 496us/sample - loss: 1.4853
Epoch 7/500
6/6 [=====] - 0s 470us/sample - loss: 1.3117
Epoch 8/500
6/6 [=====] - 0s 405us/sample - loss: 1.1723
Epoch 9/500
6/6 [=====] - 0s 616us/sample - loss: 1.0596
Epoch 10/500
6/6 [=====] - 0s 669us/sample - loss: 0.9682
```

圖 1-19 訓練神經網路

我們看到，經過前 10 個 epoch 之後，loss 從 3.2868 變成 0.9682，也就是說，只需要經過 10 次嘗試，網路的表現就比第一次猜測好三倍了，我們看看第 500 個 epoch 會怎樣（圖 1-20）。

```
Epoch 495/500
6/6 [=====] - 0s 374us/sample - loss: 2.9063e-05
Epoch 496/500
6/6 [=====] - 0s 540us/sample - loss: 2.8466e-05
Epoch 497/500
6/6 [=====] - 0s 382us/sample - loss: 2.7882e-05
Epoch 498/500
6/6 [=====] - 0s 397us/sample - loss: 2.7309e-05
Epoch 499/500
6/6 [=====] - 0s 367us/sample - loss: 2.6748e-05
Epoch 500/500
6/6 [=====] - 0s 363us/sample - loss: 2.6199e-05
```

圖 1-20 訓練神經網路——最後五個 epoch

我們可以看到 loss 是 2.61×10^{-5} ，損失變得非常小，因此模型幾乎已經找出兩個數字間的關係是 $Y = 2X - 1$ 了，電腦已經學會它們之間的模式了。

最後一行程式使用訓練好的模型來進行預測：

```
print(model.predict([10.0]))
```



在處理 ML 模型時，大家經常使用預測 (*prediction*) 這種說法，但是千萬不要把它想成預測未來！之所以使用這個詞是因為我們處理的是某種程度的不確定性，回想一下之前談過的活動偵測場景，當用戶用某個速度移動時，代表他應該是在走路。類似地，當模型學會兩件事情之間的模式時，它告訴我們答案可能是什麼，換句話說，它是在預測答案。(稍後你也會學到推理 (*inference*)，它是模型從許多答案裡選出一個，並且推測它選擇了正確的那一個。)

當我們要求模型預測「當 X 是 10 時，Y 是多少」時，你認為答案是什麼？你可以馬上想到 19，但不對，它會選出一個非常接近 19 的值，這有許多原因，首先，我們的損失不是 0，它仍然是個很小的值，所以我們可以預期，它預測的任何答案都會有極小的誤差，其次，這個神經網路只是用少量的資料來訓練的，這個例子只有 6 對 (X,Y) 值。

這個模型只有一個神經元，那個神經元會學習一個權重 (*weight*) 與一個偏差 (*bias*)，產生 $Y = WX + B$ ，這看起來正是我們想要的 $Y = 2X - 1$ 關係，我們希望它學到 $W = 2$ 且 $B = -1$ ，由於這個模型只用 6 個資料項目來訓練，我們不能預期答案就是那兩個值，而是非常接近它們的值。

請自行執行程式，看看你會得到什麼。我執行它時得到 18.977888，但你的答案可能稍微不同，因為在神經網路初始化時，有一個隨機元素——你最初的猜測會與我的稍微不同，別人的也會與我們的不同。

觀察網路學到什麼

我們在這個場景裡，用線性關係來匹配 X 與 Y ，顯然它是個非常簡單的場景，之前的小節說過，神經元會學到權重與偏差參數，所以一個神經元非常適合學習這種關係，也就是當 $Y = 2X - 1$ 時，權重是 2，偏差是 -1。在 TensorFlow 裡，我們可以觀察學來的權重與偏差，只要稍微修改程式即可：

```
import tensorflow as tf
import numpy as np
from tensorflow.keras import Sequential
from tensorflow.keras.layers import Dense

l0 = Dense(units=1, input_shape=[1])
model = Sequential([l0])
model.compile(optimizer='sgd', loss='mean_squared_error')

xs = np.array([-1.0, 0.0, 1.0, 2.0, 3.0, 4.0], dtype=float)
ys = np.array([-3.0, -1.0, 1.0, 3.0, 5.0, 7.0], dtype=float)

model.fit(xs, ys, epochs=500)

print(model.predict([10.0]))
print("Here is what I learned: {}".format(l0.get_weights()))
```

這兩個程式之間的不同在於，我建立了一個稱為 `l0` 的變數來保存 Dense 層，然後，在網路完成學習之後，我印出神經層學到的值（或權重）。

我的輸出是：

```
Here is what I learned: [array([[1.9967953]], dtype=float32),
array([-0.9900647], dtype=float32)]
```

因此，模型學到 X 與 Y 之間的關係是 $Y = 1.9967953X - 0.9900647$ 。

這非常接近我們期望的結果 ($Y = 2X - 1$)，我們甚至可以說這是比較合理的結果，因為我們假設其他的值也有這種關係。

小結

這就是你的第一個機器學習「Hello World」，你可能認為只用模型來找出兩個值之間的線性關係實在是大材小用，沒錯，但是最酷的事情在於，我們在這裡編寫程式的模式與處理更複雜的場景時的模式是一樣的，第 2 章會開始展示複雜的場景。我們將在第 2 章探索電腦視覺技術——電腦將會學習「看出」圖片裡的模式，並且指出它們裡面有什麼東西。