

# 人工智慧在醫學領域的應用—以心電圖應用為例

<sup>1</sup>國防醫學院 生命科學研究所 <sup>2</sup>三軍總醫院 家庭醫學科  
陳楷傑<sup>1</sup> 方文輝<sup>2</sup>

## 前言

近年來隨著人工智慧(Artificial Intelligence, AI)的進步，特別是OpenAI在2022年11月推出ChatGPT，使AI技術更迎來了一個新的高峰。醫學領域是其中一個最引人矚目的範疇，其影響廣泛且多元。AI基於大數據和機器學習能力，能夠從龐大的醫療數據中提取關鍵信息，協助醫生更精確地診斷疾病。這種技術不僅節省了診斷時間，也提供了更早期、更精準的診斷，從而改善了治療效果。總體而言，AI在醫學領域的應用不僅改變了診斷和治療的方式，還推動了醫療系統的革新和升級。它為醫護人員提供了更多工具和資源，也讓病人能夠享受到更高品質、更個性化的醫療服務。這種技術的不斷進步無疑將為未來的醫學帶來更多創新和進步。在這篇文章中，將深入探討AI的發展、技術背後的原理以及其在醫學領域相關應用。

## AI發展史

### 1. 起源(1950-1960)：

人工智慧名詞於1956年達特茅斯會議(Dartmouth workshop)人工智慧研究計畫中提出<sup>1</sup>，這個時期人們對於機器是否能模擬人類智能產生了激烈的興趣，以圖靈(Alan Turing)提出的圖靈測試最為著名，若一台機器與人類對話且無法被辨識出其機器身份，則可視該機器具備智慧，給予了「智慧」明確的定義。

### 2. 知識推論和專家系統(1960-1990)：

這時期的人工智慧以「真」和「假」來理解，應用面向主要集中在代數和數學證明。

簡而言之，電腦透過各種演算法將輸入與輸出資料中尋找最佳的線性方程式來預測可能的答案。專家系統是由專家系統之父Edward Feigenbaum所發明<sup>2</sup>，專家系統是由大量的知識庫與推理規則構建而成，這才能處理複雜問題。但是需要大量的維護工作，且應用範圍有所限制。隨著其他演算法的不斷進步，專家系統漸漸走向下坡。

此時期發展沒多久就遇到一些困難，電腦的記憶體有限且處理速度較慢，使得其計算能力受到限制，無法解決複雜問題。同時，當時的人工智慧無法回答人類不知道的問題，且應用範圍並不如預期廣泛。

### 3. 機器學習(1990-至今)：

此時期的發展加入了統計機率概念，這使得能夠描述事件發生的機率，而不僅僅是「True」和「False」的判斷。在資料處理方面，人類必需將「特徵值」告知電腦。機器學習包括支持向量機(Support vector machine)<sup>3</sup>、決策樹(Decision Tree)<sup>4</sup>、隨機森林(Random Forest)<sup>5</sup>等演算法，這些方法能夠處理非線性資料並進行非線性分割，更貼近現實狀況，因此受到廣泛關注。

### 4. 深度學習(2000-至今)：

深度學習是機器學習的分支，而深度學習第一次被提及是在2006年Geoffrey Hinton發表於Science的論文中<sup>6</sup>。深度學習發展前期有幾個關鍵技術，第一個關鍵技術當屬反向傳播法(Backpropagation)<sup>7</sup>，由Geoffrey Hinton等人於1986年研究發展出，直到今天為止99%以上

的神經網路優化都採取反向傳播法進行；第二個是1989年Yann LeCun研究的卷積神經網路（Convolutional Neural Networks, CNN）<sup>8</sup>，這奠定未來神經網路在影像分類任務上的突破。而深度學習展前期，因為梯度消失問題以及運算資源的不足，使得無法訓練過深的網路，限制了網路預測的準確性。

在當時Geoffrey Hinton優化了反向傳播法，且成功訓練不超過10層「深度神經網路」，獲得很大的進展，且發表於Science的論文中，而深度學習字眼也第一次被提及在文獻當中<sup>6</sup>，因此Geoffrey Hinton被尊稱為「神經網路之父」、「深度學習之父」，儘管現在他提出的方法已被當前技術給淘汰，但這引導人們走向深度學習的經典文獻。

近代深度學習發展史與「ILSVRC」圖像識別競賽結果息息相關，這要歸功於史丹佛大學的李飛飛，從2005年開始收集大量帶有標註的圖片供影像視覺模型訓練，並於2007年創辦「ImageNet<sup>9</sup>」。

在2012年ILSVRC的比賽中Alex Krizhevsky和Geoffrey Hinton所提出的「AlexNet<sup>10</sup>」，使錯誤率從26%大幅地降低至16%。在2015年的ILSVRC，微軟亞洲研究院何愷明的團隊發展出的「ResNet<sup>11</sup>」將錯誤率降低至3.57%，使AI領域又再次有重大的突破，大幅超越2014年冠軍「GoogleNet<sup>12</sup>」的6.7%錯誤率以及人類的5.0%平均錯誤率，且更重要的意義是真正解決梯度消失的問題，並可以成功訓練1000層深的網路，幾乎當時沒有團隊能訓練超過50層的

神經網路，在這之後深度學習的研究和應用進入到一個快速蓬勃發展時期。

在2022年OpenAI發行ChatGPT後，使人工智慧進入了另一個高峰，巨大的改變人類生活型態，而ChatGPT基礎模型是由Google於2017年所發展的Transformer模型<sup>13</sup>，至今大部分自然語言模型的基礎都Transformer模型衍生而來，且許多研究將Transformer模型應用在影像識別的領域上，換句話說Transformer模型可以各別應用在自然語言和影像任務上，當今的學者嘗試著將自然語言和影像識別做結合發展出「多模態模型」，這使現在的AI更像人類可以同時做出很多預測。

## AI技術

### 一、機器學習

#### 1. 決策樹(Decision Tree)<sup>4</sup>

決策樹是一種在機器學習領域中常用的模型，它模擬了人類在做出決策時的思考過程。該模型使用樹狀結構表示多個決策規則和結果，從而使得複雜的決策過程變得清晰可解釋。

在決策樹中，樹的每個節點代表一個屬性或特徵，每個分支代表一個屬性的取值，而每個葉子節點表示一個結果或決策。建構決策樹的過程就是通過將數據集根據屬性進行不斷的劃分，使得每個分支上的數據更加純淨。

決策樹的優勢之一是易於理解和解釋。由於樹狀結構的直覺性，我們可以輕鬆地解

釋模型的決策邏輯，這使得它在實際應用中得到廣泛使用。此外，決策樹不需要太多的數據預處理，能夠處理混合型數據，包括數值型和類別型特徵。

然而，決策樹也存在一些缺點。容易過擬合(overfitting)是其中一個主要問題，意思是指在訓練數據上表現非常好，但在處理新的測試數據時表現不佳。這是因為決策樹過於深入地學習了訓練數據，而不是泛化出適用於新數據的規律。特別是在樹的深度較深時。為了解決這個問題，可以通過剪枝來限制樹的深度。此外，決策樹對輸入數據的細微變化敏感，可能導致不同的樹結構和結果。

決策樹可用於分類和回歸問題。在實際應用中，我們可以通過調整參數、剪枝等手段來提高模型的性能，使其更適應不同的數據場景。

## 2. 隨機森林(Random Forest)<sup>5</sup>

隨機森林它基於決策樹的概念，通過結合多個決策樹的預測結果，提高整體模型的準確性和穩定性。

隨機森林的核心思想在於隨機選取數據和特徵進行建模。在每個決策樹的訓練過程中，隨機從訓練數據中有放回地抽樣，同時也隨機選取特徵進行節點的劃分。這樣的隨機性確保了每棵樹的差異性，減少了單一決策樹容易過擬合的問題。

隨機森林的優勢之一是在處理大量高維數據時表現出色。它能夠處理數據中的缺失

值，同時也能夠評估特徵的重要性，有助於進行特徵選擇。此外，隨機森林對於不平衡數據集的處理能力較強。

然而，隨機森林的模型解釋性相對較差，雖然可以得知特徵的重要性，但難以解釋單一決策樹的具體邏輯。另外，在某些情況下，隨機森林可能會低估模型的不確定性。

隨機森林具有良好的性能和廣泛的應用。在實際使用中，可以透過調整參數、增加樹的數量等手段進一步提升模型性能。

## 3. 支持向量機(Support vector machine)<sup>3</sup>

支持向量機主要應用於分類和回歸任務。它的核心思想是在特徵空間中找到一個最佳的超平面，將不同類別的數據點有效地分開。

支持向量機的目標是找到一個決策邊界，使得兩類數據點之間的邊界距離最大化。這個決策邊界通常是一個超平面，可以是線性的，也可以是非線性的，這取決於所選擇的核函數。

在訓練支持向量機時，模型會選擇一組支持向量，這些是離決策邊界最近的數據點。支持向量機的優勢之一是對於高維數據的處理能力，即使在特徵空間的維度較高時，它仍能保持良好的性能。

支持向量機的應用不僅限於線性問題，還可以通過使用不同的核函數處理非線性問題。這使得支持向量機在圖像分類、文本分類和生物信息學等領域得到廣泛應用。

然而，支持向量機的主要挑戰之一是對於大規模數據集的訓練和預測速度較慢，特別是在非線性核函數的情況下。此外，對於核函數的選擇和參數的調整也需要較多的專業知識。

支持向量機是一個靈活且具有廣泛的應用領域。在實際使用中，選擇適當的核函數和參數是關鍵，以實現最佳的模型性能。

#### 4. 梯度提升機(Extreme gradient boosting, Xgboost)<sup>14</sup>

梯度提升機屬於集成學習的一種。它以弱學習器為基礎，通過迭代地訓練一系列模型，逐步提升整體模型的性能。

梯度提升機的核心思想在於通過不斷迭代訓練，每一次迭代都根據前一次的預測結果計算出誤差，然後擬合一個新的模型來修正這個誤差。這樣，模型的預測能力逐步提高，最終得到一個強大的整體模型。

梯度提升機的優勢之一是能夠處理不同類型的數據，包括數值型和分類型特徵。它同樣適用於解決分類和回歸問題。此外，梯度提升機能夠自動處理缺失值，減少了對數據預處理的需求。

在實際應用中，梯度提升機通常擁有良好的性能，尤其在處理結構化數據和表現非常優秀。然而，它也有一些挑戰，如對超參數的敏感性、可能出現過擬合現象等。因此，通常需要通過交叉驗證等手段來調整模型參數，以達到最佳性能。

梯度提升機是一個靈活、高效的機器學

習算法，廣泛應用於各種領域，包括金融、保險、醫療等。在使用時，適當調整超參數並避免過擬合是確保模型性能的關鍵。

### 二、深度學習

#### 1. 梯度下降法(Gradient Descent)<sup>15</sup>

梯度下降法是機器學習和深度學習中廣泛應用的優化算法，目標是在模型訓練過程中找到最優的參數組合，使損失函數的值逐漸趨於最小，從而提高模型的性能。

在梯度下降法中，計算目標函數對於模型參數的梯度，梯度的方向是目標函數增長最快的方向，並以梯度的反方向，即目標函數減小最快的方向，來更新模型的參數，這個過程不斷迭代，直到滿足停止條件。

梯度下降法的一個重要超參數是學習率，它控制每次更新參數的步伐，學習率過大可能導致不穩定，而學習率過小則可能使收斂速度過慢，選擇適當的學習率對梯度下降法的性能至關重要。

總的來說，梯度下降法為模型訓練提供了一個強大的工具，並在機器學習和深度學習領域中取得了廣泛的成功應用。

#### 2. 反向傳播法(Backpropagation)<sup>7</sup>

反向傳播法是深度學習領域中重要的優化算法，它在神經網絡的訓練過程中扮演著關鍵角色。這種方法的核心目標是通過計算和調整神經網絡中權重的梯度，以最小化模型的損失函數，從而使模型能夠更好地擬合數據。

在反向傳播法的運作過程中，首先進行正向傳播，將輸入數據經過網絡傳遞至輸出層，計算網絡的預測輸出。接著，通過比較預測輸出和實際標籤的方式計算誤差。隨後，開始反向傳播，從輸出層開始計算每個層的梯度，將誤差反向傳播至輸入層。最後，使用梯度下降法，根據梯度對每個權重進行調整，進而使得整個模型的損失函數逐漸趨於最小值。

反向傳播法的啟發源於生物神經網絡的學習過程，並被廣泛應用於深度學習模型的訓練中。雖然存在一些限制，例如梯度消失問題，但反向傳播法使得神經網絡能夠自動學習特徵值，成為深度學習領域取得成功的重要工具之一。

### 3. 多層感知機(Multilayer Perceptron, MLP)<sup>16</sup>

多層感知機是一種廣泛應用於深度學習的監督式學習模型，其結構包含輸入層、隱藏層、以及輸出層。這種神經網絡模型透過多層次的結構，能夠更有效地進行複雜的非線性建模和自動學習特徵值。

在多層感知機的結構中，輸入層接收原始輸入數據，每個節點代表輸入特徵；隱藏層位於輸入層和輸出層之間，其中每個隱藏層包含多個神經元，每個神經元與前一層的所有神經元相連；輸出層提供整個模型的輸出，節點數量取決於任務的性質。

為了引入非線性特性，多層感知機在隱藏層和輸出層的每個神經元上加入非線性轉換函數，其中包括常見的Sigmoid和ReLU等

函數。非線性轉換函數能夠使模型處理更複雜的問題。

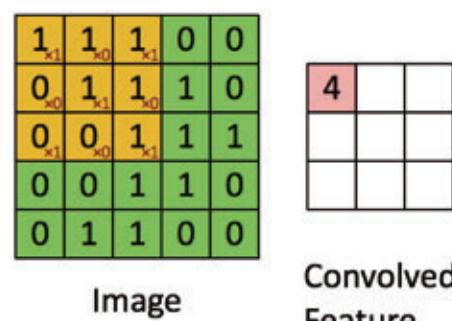
隨著深度學習領域的不斷發展，其他模型如卷積神經網絡的興起，逐漸超越了傳統的多層感知機，但其在深度學習歷史中仍佔有一席之地。

### 4. 卷積神經網路(Convolutional Neural Network, CNN)<sup>8</sup>

神經網路最初的構想是模擬大腦運作的過程，多層感知器中的「全連接層」試圖模擬腦細胞間傳遞訊息的思考過程。然而，生物研究發現貓咪的腦部細胞在受到不同形狀的圖像刺激時，感受野的腦部細胞會產生不同反應。這些細胞在接觸光影訊號時，每個細胞會辨認特定的簡單特徵，而且這些簡單特徵在視野範圍內的任何位置都會被激活。

電腦學家受到了生物研究的啟發，因此在多層感知器的全連接層之前增加卷積器(convolution filter)，卷積器模擬了感受野最初的細胞，負責用來辨認特定特徵。

卷積器通過「濾鏡」對圖片進行全局搜索（圖一），生成「特徵圖」。在特徵圖



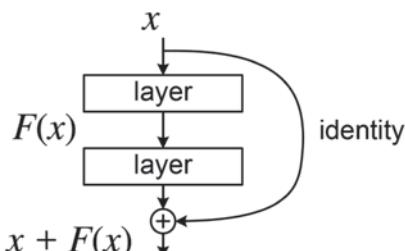
圖一 卷積器操作示意圖<sup>8</sup>

上，數字越大表示該區域越符合卷積器所負責的特徵。獲得特徵圖後，會應用非線性函數進行轉換，以避免訊息的重複。由於連續卷積可能導致訊息的冗餘，為了節省計算量，引入了「池化層」(pooling layer)。池化層降低圖片的解析度，相當於對圖片進行降維。整體而言，這樣的卷積神經網路結構能夠更有效地捕捉圖像中的特徵，提高模型的性能。卷積器能有效自動學習圖像中的特徵，不需要手動設計特徵提取器，這使卷積神經網路成為圖像分類、物件偵測、物件分割等領域的重要工具。

## 5. 殘差神經網路(Residual Neural Network, ResNet)<sup>11</sup>

殘差神經網路是一種深度學習模型，由微軟的何愷明團隊提出，其獨特的設計解決了深度神經網路中常見的梯度消失和梯度爆炸問題，使得訓練深度網路變得更加穩定且有效。

圖二顯示殘差神經網路的核心思想是引入殘差學習，這一概念旨在讓模型學習輸入和輸出之間的殘差，這種結構使得模型更容易學習恆等映射，同時避免了梯度消失的問題。



圖二 ResNet殘差架構

每個殘差塊包含兩個分支，一個是恆等映射，另一個是透過卷積層學習的殘差。這兩個分支的結果相加，並通過激活函數進行非線性轉換。這種殘差塊的結構被堆疊在一起，形成深度網路，使得模型能夠學習更複雜的特徵。這使得模型深度大幅增加，這種深度結構在圖像識別等任務上表現優異。全局平均池化被引入以減少參數數量，同時提高模型的泛化能力。

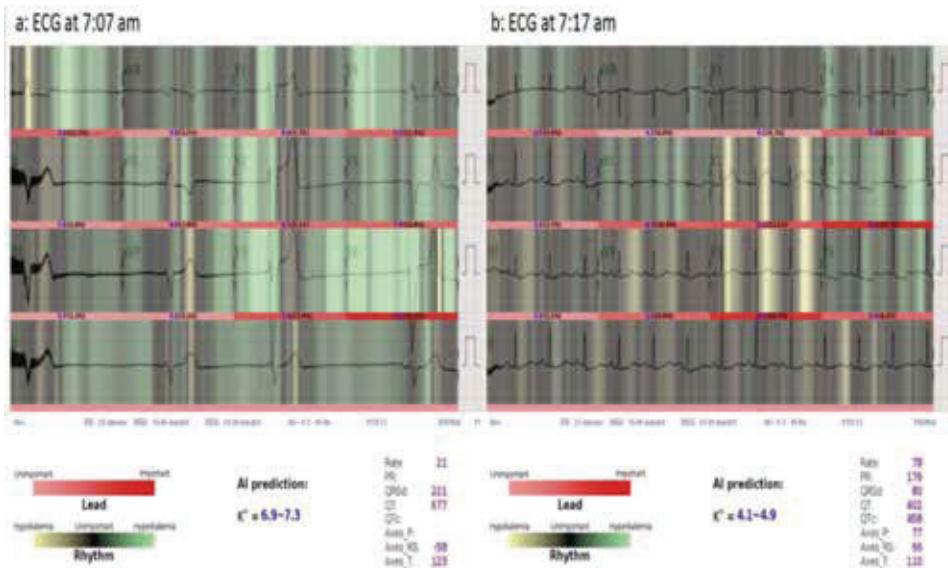
總的來說，殘差神經網路的提出不僅在深度學習領域取得了巨大成功，還為後來的模型設計提供了有價值的啟示。

## 6. Transformer<sup>13</sup>

Transformer是一種革命性的深度學習模型，最初用於自然語言處理任務，如機器翻譯。它的獨特結構使其在多個領域都表現優越，包括語音識別、圖像生成和其他序列到序列的任務。

Transformer的核心創新之一是引入了自注意機制(Self-Attention Mechanism)。這種機制允許模型同時關注輸入序列的不同位置，而不是像傳統的循環神經網路(RNN)或長短時記憶網路(LSTM)那樣依賴序列順序進行處理。這使得Transformer在處理長範圍依賴性時更為靈活，並且能夠更有效地捕捉序列中的上下文信息。

另一個Transformer的特點是多頭注意力機制(Multi-Head Attention)。這允許模型同時對不同的表示子空間進行注意力運算，從而更好地捕捉不同特徵之間的關係。每個注



圖三 某醫學中心心電圖AI預測－案例一

意力頭都學習一種不同的表示，這樣整體上能夠更全面地理解輸入序列。

除了自注意機制，Transformer還包括位置編碼(Positional Encoding)，這是為了在模型中引入序列的結構信息，以處理序列中元素的位置。這對於處理語言等序列數據中單詞的順序是至關重要的。

Transformer的編碼器-解碼器結構使其非常適合序列到序列的任務，例如機器翻譯。它的解碼器部分還包括遞歸層，這有助於生成輸出序列。

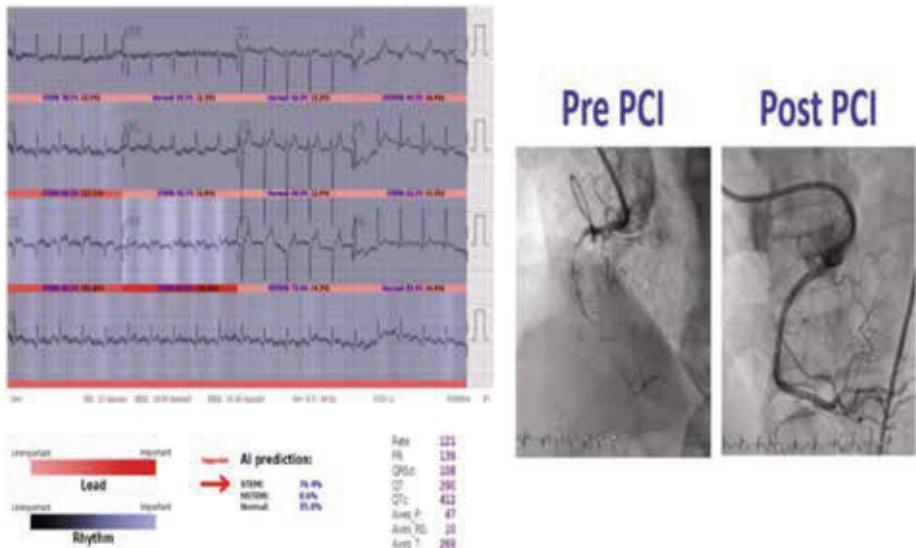
由於Transformer的出色性能和多用途性，它已經成為深度學習中的一個重要里程碑，並在各種應用中取得了卓越的成果，像是OpenAI的ChatGPT。其開創性的結構和強大的表徵學習能力對於推動自然語言處理和其他領域的研究和應用有著深遠的影響。

## AI於心電圖的應用

心血管疾病是一個重要的公共衛生議題，篩檢和診斷在減輕這些疾病負擔方面至關重要。在所有檢測中，心電圖檢測價格合理且簡單的診斷工具。然而，心電圖的判讀即使是受過專業訓練的醫師也未必能完全掌握。

本團隊已經透過深度學習開發出能夠準確幫助篩查慢性心血管疾病並檢測急性心血管事件的人工智能輔助心電圖分析系統，該系統不僅可以針對疾病做預測包括心肌梗塞和心房顫動等疾病，還可以做連續數值預測像是血鉀離子濃度、心臟射出率和心臟年齡等等，並且實際在某醫學中心做應用，該醫學中心只要有做心電圖都會經過人工智能輔助心電圖分析系統即時分析，並且有發生異常時會立即提醒值班醫師。

圖三呈現了一位於2019年3月4日早上7:00時被送至某醫學中心的65歲昏迷男性的病例。該病人有末期腎衰竭的病史，心跳僅為每分鐘21下。在7:07時，我們立即進行了第一次心電圖檢測，同時實驗室檢測血鉀的結果預計在7:44時才能獲得。面對這一緊急情況，我們迅速採用了AI進行鉀離子濃度的預測，預測結果顯示其鉀離子濃度在6.9至7.3之間。隨後，



圖四 某醫學中心心電圖AI預測及心臟血管攝影－案例二

我們立即進行了降低血鉀濃度的治療，短短幾分鐘後，病人的心跳恢復至每分鐘99下。新的心電圖顯示，在血鉀濃度正常化後，病人狀態穩定。最終，在進行透析治療後，病人成功康復並順利出院。

圖四描述了一名90歲末期腎衰竭的女性，規劃於2020年4月28日早上在某醫學中心接受洗腎廈管手術。根據標準程序，在手術前，她接受了一次心電圖以評估麻醉風險。AI立即檢測到可能存在心肌梗塞的情況，並立即通知了心臟內科值班醫師。隨後，心臟內科迅速啟動了心導管手術團隊，延遲了原定的洗腎廈管手術，並進行了緊急的心導管介入。手術結果顯示，她的兩條血管均受阻，如果按原計劃進行洗腎廈管手術，可能面臨極高的手術風險，甚至可能導致手術中死亡。經過心導管手術後，患者的心臟供氧血流得到了明顯的改善。這次

及時的AI檢測和介入挽救了患者的生命，阻止了一場可能致命的手術。

人工智慧輔助心電圖分析系統應用在臨牀上，不僅輔助醫師判讀，也縮短檢測時間，像是血鉀濃度檢測，甚至提早發現病人可能發生疾病的事件。

## 討論

人工智慧的重要性和應用價值在各個領域逐漸凸顯，但在發展的過程中也面臨許多挑戰和問題。在醫學領域，最直接的挑戰就是資料問題，特別是在針對特定疾病進行模型訓練時。樣本不平衡問題是常見的挑戰之一。如果目標疾病存在分級，通常越嚴重的病例或健康樣本會更難取得，導致資料集中不同類別的樣本數量不均。在這種情況下，模型在訓練過程中容易偏向於樣本數較多的類別，從而降低對其他類別的識別能力。為了解決這一問題，可以採用資料擴增的方法，例如利用數據增強技術生成更多稀有類別的樣本；或者在訓練時對於類別較少的樣本提高抽樣機率，增加模型學習這些類別的機會。對於罕見疾病或盛行率低的疾病，資料量少的問題更加顯著。如果直接用有限的資料訓練模型，通常會導致模型準確

度不佳。為此，可以採用轉移特徵學習的技術。首先在大型的公開資料庫上預訓練模型，使其學習到通用特徵，然後將預訓練模型的權重固定，專注於針對目標疾病進行微調訓練。這種方法能有效提高模型對目標疾病的識別準確度，即使在病例數有限的情況下也能取得良好效果。

透過上述方式，人工智慧在醫學領域的發展不僅能克服資料的挑戰，還能更好地應用於實際的臨床場景，從而發揮其真正的價值。臨床人員對於人工智慧的應用仍存有疑慮，尤其是在直接依賴人工智慧預測結果進行診斷時，模型預測的可解釋性顯得尤為重要。如果模型的運作過程不透明，醫師可能難以信任人工智慧的結論，進而影響實際應用的推廣。可視化技術是一種有效的方法，可以幫助醫師理解模型的決策邏輯。例如，影像識別模型中使用熱圖(heatmap)來突出模型認為重要的影像區域，讓醫師能清楚看到模型基於哪些特徵進行判斷，從而提高信任感。然而，隨著大語言模型（如ChatGPT）等技術的興起，如何解釋語言模型的運作變得更加複雜。在語言模型的應用中，模型是通過計算前文的上下文相關性來預測下一個文字，但這種運作過程的可視化並不直觀。對於語言模型，可視化可能需要著重於模型如何處理句子結構、詞彙關聯性以及語境間的依賴性。例如，透過注意力機制(Attention Mechanism)的權重圖，展示模型在生成每個詞彙時所關注的上下文部分。此外，設計簡單易懂的交互式界面，能幫助臨床人員

更好地理解模型的語言處理過程。總之，模型的可解釋性不僅僅是提升技術信任的工具，也是讓人工智慧與臨床應用無縫結合的重要橋樑。未來研究可以探索更具創新的可視化方式，特別是在語言模型的領域，以促進人工智慧技術在醫療中的進一步落地和應用。

人工智慧在醫療領域的廣泛應用雖然帶來了技術上的突破，但同時也伴隨著一系列的倫理挑戰，模型的表現高度依賴於訓練數據的質量和多樣性。如果訓練數據集中某些族群的樣本不足，可能導致模型在這些群體上的預測結果不準確，更嚴重的話會有歧視問題。例如，模型可能對某些性別、年齡或種族的診斷表現欠佳，從而加劇醫療的不公平性。因此，在開發人工智慧系統時，應確保數據集的多樣性和代表性，並對模型進行公平性測試以減少偏見；醫療數據涉及高度敏感的個人信息，人工智慧的開發和應用需要遵守嚴格的隱私保護規範。例如，數據的匿名化處理和加密存儲是保障患者隱私的重要措施。此外，開發者需遵循當地法律以確保數據的合法使用，同時避免數據被濫用或洩露；當人工智慧在診斷或治療中出現錯誤時，責任應如何劃分是一個重要的倫理問題。是系統開發者、醫療機構還是使用人工智慧的醫師應該承擔責任？這需要建立明確的法律框架來規範。只有在技術發展的同時充分考慮這些倫理挑戰，人工智慧才能在醫療領域實現更廣泛且負責任的應用。

## 結論

人工智慧的應用擴展到各個醫療專業領

域。這不僅有助於提供更優質、智能化的醫療服務，同時也能夠協助醫療決策，提升病人的安全水平。我們致力於將先進的技術融入醫療實務，以促進整體醫療水平的提升。

### 參考文獻

1. Crevier D: AI: The Tumultuous History of the Search for Artificial Intelligence. 1993.
2. Grier DA: Edward feigenbaum. IEEE Annals of the History of Computing 2013; 35(4): 74-81.
3. Cortes C: Support-Vector Networks. 1995.
4. Loh WY: Classification and regression trees. Wiley interdisciplinary reviews: data mining and knowledge discovery 2011; 1(1): 14-23.
5. Breiman L: Random forests. Machine Learning 2001; 45: 5-32.
6. Hinton GE, Salakhutdinov RR: Reducing the dimensionality of data with neural networks. Science 2006; 313(5786): 504-7.
7. Rumelhart DE, Hinton GE, Williams RJ: Learning representations by back-propagating errors. Nature 1986; 323(6088): 533-6.
8. LeCun Y, Boser B, Denker JS, et al: Backpropagation applied to handwritten zip code recognition. Neural Computation 1989; 1(4): 541-51.
9. Deng J, Dong W, Socher R, et al: ImageNet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 2009; 248-55.
10. Krizhevsky A, Sutskever I, Hinton GE: Imagenet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems 2012; 25: 1097-105.
11. He K, Zhang X, Ren S, et al: Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016; 770-8.
12. Szegedy C, Liu W, Jia Y, et al: Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015; 1-9.
13. Vaswani A, Shazeer N, Parmar N, et al: Attention is all you need. Proceedings of the 31st International Conference on Neural Information Processing Systems 2017.
14. Friedman, JH: Greedy function approximation: a gradient boosting machine. Annals of statistics 2001; 29(5): 1189-232.
15. Cauchy MA: Méthode générale pour la résolution des systèmes d'équations simultanées. Comp Rend Sci Paris 1847; 25(1847): 536-8.
16. Rosenblatt F: The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review 1958; 65(6): 386-408. 