機器學習應用於半導體先進製程

三維多參數結構量測

周柏文/顧逸霞

由於電晶體尺寸逐漸接近物理極限,因此近年來發展晶片立體堆疊設計,並採用矽通孔 (TSV, through silicon via)核心製程技術成為延續摩爾定律的重要方法。本研究建立了多參數物 理模型以進行量測光譜擬合,可用來分析矽通孔三維形貌參數,並已經由掃描式電子顯微鏡 (Scanning Electron Microscope, SEM)切片影像驗證為非破壞性、高準確度的量測方法。但由 於多參數擬合須多次迴圈逼近相對耗時,因此本研究結合機器學習方法,實驗結果顯示各參數的 決定係數(Coefficient of determination; *R*²)高達0.99,且量測分析時間≤10毫秒。本研究證實 機器學習的導入大幅提升量測速度,未來可應用在先進封裝製程三維結構的多參數量測。

一、 前言

(1) 研究緣起

摩爾定律是由Intel公司的Gordon Moore所提出,其核心是預測每單位面積上 的電晶體數量倍增所需的時間。然而近年來 由於電晶體尺寸逐漸接近物理極限,縮小電 晶體的難度越來越高,因此開發晶片立體堆 疊設計,並採用矽通孔核心製程技術成為延 續摩爾定律的重要方法。由於矽通孔的高深 寬比三維結構參數,包含孔深(depth)、孔 底曲率(curvature)及粗糙度(roughness), 是影響後續填銅後形成立體導線的長度及電 子訊號傳輸效能的關鍵,過去多採用掃描式 電子顯微鏡進行矽通孔剖面檢測,昂貴、耗 時且為破壞性。本研究近期建立了多參數物 理模型來進行矽通孔量測光譜擬合分析,可 用以分析矽通孔三維形貌參數,流程圖如圖 一虛線所示。但由於建立多個物理模型較為 複雜耗時,且由於各個參數對反射光譜波形 特徵的影響具高度相關性,因此演算分析流 程須進行多次迴圈式擬合,才能逐漸逼近最 佳分析結果,約需耗時1-2小時。本研究期 望開發一種快速、高準確度、非接觸性的量



測方法,可實際應用在複雜立體元件的多參 數量測分析。

圖一 迴圈式擬合與機器學習流程圖

(2) 研究目的

本研究目的是使用非破壞性的光學量測 方法,搭配機器學習訓練模型來還原矽通孔 三維形貌,並且提出優化模型超參數的方式, 從而達到提升量測準確度與縮短模型訓練時 間。首先本研究將矽通孔結構的三維參數, 包含深度、粗糙度、有效面積比(effective area),帶入物理模型計算出不同量測波長 所對應的干涉光譜強度(intensity),並且利 用光譜強度標準化的作法將其換算成反射率, 以取得大量可靠的數據用以發展機器學習模 型,最終可應用訓練完成模型,用來即時預 測矽通孔量測樣本微結構的深度、粗糙度、 有效面積比三個參數,流程圖如圖一實線所 示,並接著還原出三維立體結構形貌。本研 究結合了原有光學量測方法,而由機器學習 模型取代原本較為繁複耗時的擬合演算流程, 加速得到多參數量測結果,使其能夠與先進 的立體封裝製程整合,具備高準確度,又能 即時回饋量測數據並優化製程的目的。

二、 研究方法

(1) 矽通孔物理模型與參數影響

理想的矽通孔量測光路如圖二 (a) · 孔 底理想的反射有效面積比如圖二 (c) · 但實 際在量測矽通孔時受到三維多參數結構的影 響 · 如圖二 (b) · 由於矽通孔底部曲率的影 響·實際孔底可反射光面積如圖二 (d)。通 常對光譜造成劇烈影響的有三個主要參數· 分別是矽通孔的深度、粗糙度、有效面積 比。



圖_(a) 埋想矽通孔剖面圖。(b) 實際矽通孔剖面圖。 (c) 理想矽通孔底部俯視圖。(d) 實際矽通孔底部俯視圖

$$E_{via} = \left(\frac{e}{a}\right) \sqrt{(1-\alpha)e^{\left[-(4r_q\pi)^2/\lambda^2\right]}E_0r_{si}^+e^{\left[i2\pi\left(\frac{2d}{\lambda}\right)\right]}}$$
(1)

孔深會使反射光譜震盪訊號的頻率改 變,底部粗糙度會導致光譜訊號衰減,尤其 是在短波長衰減更加嚴重,底部有效面積會 使光譜訊號在整個量測光譜範圍整體縮減。 公式如式(1)所示,其中*E*_{via}為孔底反射電 場,*e*, *a*分別為孔底有效半徑與孔洞半徑。 *α*與1-*α*分別為照射光點內晶圓表面以及孔 洞所占面積比。*r_q*為粗糙度,定義為表面高 度與平均表面高度的均方根偏差(rootmean-square deviation; RMSD) 。 λ 代表 量測波長 · E_0 為入射光的電場 · r_{si}^+ 為當材料 為矽晶圓(silicon)時的菲涅耳(Fresnel)反射 係數 · d為矽通孔的深度^[1]。

矽通孔結構量測理論模型是由晶圓表面反射訊號與矽通孔底部有效面積反射訊號所形成的干涉光譜訊號所組成 · 如圖二(b)所

示。干涉光譜強度的模擬模型公式如式(2)所 示,本研究帶入不同範圍的深度、粗糙度與 有效面積比數值,面積比α,波長λ,以及電 場*E*₀可計算出光譜中對應波長的光強數值, 據此將可為機器學習模型建立大量的訓練數 據集。

$$I = \alpha (r_{si}^{+} E_{0})^{2} + (1 - \alpha) e^{\left[-(4r_{q}\pi)^{2}/\lambda^{2}\right]} (r_{si}^{+} E_{0})^{2} \left(\frac{e}{a}\right)^{2} + 2\sqrt{\alpha (1 - \alpha) e^{\left[(4r_{q}\pi)^{2}/\lambda^{2}\right]}} (r_{si}^{+} E_{0})^{2} \left(\frac{e}{a}\right) \cos(2\pi (2d/\lambda^{2}))$$
(2)

由於實際量測時每一次入射光所產生的 電場數值*E*₀並不相同,因此本研究將光譜訊 號進行正規化(normalization)的前處理^[2], 正規化如式(3)所示,其中*E*_{exp}為量測到的孔 底反射與表面反射干涉能量 · E_d 為暗電流 (dark current)能量 · E_{ref} 為晶圓表面時反射 能量 。

$$R = \frac{E_{exp} - E_d}{E_{ref} - E_d} \tag{3}$$

本研究的量測光譜與理論模型光譜比較 如**圖三**所示,所量測的矽通孔孔徑約為5微 米,週距(pitch)約為10微米,面積比α約為 81%,其中實線光譜為實際量測到的反射率 光譜,虛線光譜則為理論模型擬合所產生的 反射率光譜。經由理論模型擬合可以得到深 度約為65.08微米,粗糙度約為110奈米,有 效面積為11.97%。過去採用掃描式電子顯 微鏡切片影像驗證,可直接比對深度與粗糙 度的結果,底部的有效面積則可透過橢圓模 型理論來推算,如式(4)及式(5)推導。其中 (e^2 / a^2) 為有效面積。 Δd_{via} 為深度解析 度, d_{via} 為矽通孔深度, $\Delta \lambda$ 為CCD的像素解 析度, $\bar{\lambda}$ 為平均波長,a為矽通孔底部橢圓 形貌的長軸,b為孔底橢圓形貌的短軸^[1]。



圖三 理論模型套用實際參數與量測模組量測之波長與反射率比較圖

$$\Delta d_{via} = \frac{d_{via} * \Delta \lambda}{\bar{\lambda}} \tag{4}$$

$$\frac{e^2}{a^2} + \frac{(-b + \Delta d_{via})^2}{b^2} = 1$$
(5)

(1) 反射式光譜量測

我們使用商用的薄膜量測儀^[3]來量測對 矽通孔樣本來進行量測,以實際量測的結果 來驗證使用理論模型數據所完成的機器學習 模型。矽通孔樣本所取得的干涉光譜通常會 呈現在直流訊號上存在著規律性的振幅振 盪。

(2) 機器學習架構介紹

本研究建構機器學習模型訓練的整體架 構如圖四所示·由數據前處理及模型訓練過 程兩個部分所構成·使用的程式語言為 python 3.10.9 ·模型為隨機森林回歸 (random forest regressor),此模型是由複 數決策樹(decision tree)所組成,當數據輸 入模型時每一個決策樹會輸出一個預測的數 值,最後由這些數值的平均值來決定模型輸 出值。而選擇隨機森林回歸主要有以下優 勢:第一,模型較簡易,相較於神經網路而 言架構上較簡單。第二,訓練速度快,單一 訓練模型時間只要 ≤ 700秒。第三,預測速 度快,單一樣品的預測只需用時 ≤ 10毫 秒。第四,透過結合許多決策樹的結果,使 其具備抗過擬合(anti-overfitting)的能力。



圖四 機器學習模型流程圖

- (3.1) 數據前處理
- (1) 定義參數範圍

第一步是藉由式(2)來產生特定合理範圍 的數據,由於在計算時只要給定深度、粗糙 度、有效面積比、波長λ及光斑下孔洞與晶 圓表面面積比α,入射表面電場E₀即可算出 光強,因此可透過六大參數來產生數據。

(2) 模擬理論光譜

由於本文著重三維結構,因此模型輸出 主要為深度、粗糙度、有效面積比三參數, 而其餘參數可作為輸入特徵。因此會選定合 理範圍的深度、粗糙度、有效面積比,並透 過量測模組來確定其餘參數,便可產生機器 學習的數據。

(3) 計算反射率

考量到不同量測模組所使用的照射光 源、量測干涉光譜的光譜儀、及各項光路元 件會有機差,在這一步驟會將模擬光譜從能 量利用式(3)轉換成反射率,這樣一來即使使 用不同量測模組也不會影響準確度。

(4) 創建資料集

在產生大量的數據後,需要將該數據的 波長與反射率之關係圖以特徵的形式以及對 應的深度、粗糙度、有效面積比以輸出的形 式存儲下來,在實驗中將數據以資料庫的方 式將其儲存下來。經過實驗證實,存入約 200,000筆數據時只需花費約16分鐘,讀取 數據只花費約半分鐘。

(3.2) 模型訓練過程

(1) 讀取資料

從資料庫中讀取反射率光譜、深度、粗 糙度、有效面積比四個參數,並將數據切割 成訓練集及測試集,比例為8:2。 (2) 訓練模型

機器學習的系統架構如圖五所示。由於 輸出為3種不同的參數,因此在訓練時就會 為3個參數各訓練一個模型。模型的輸入特 徵將會是反射率光譜,輸出參數是深度、粗 糙度、有效面積比其中之一。最終會產生3 個不同的模型分別預測3個輸出參數,並透 過測試集計算3個模型的準確度。



圖五 機器學習的系統架構

(3) 評估模型準確度

為了增加模型的可靠性·採用3種不同 的方式來評估模型的準確度。

A. 均方誤差 (mean squared error, MSE) 均方誤差的功能是計算模型的預測輸出與測

試集數據的誤差。公式如式(6)所示,其中n 為樣本數,y_i為第i個測試集上的數據實際 值,ŷ_i為對應第i個數據的預測值。MSE越小 代表輸出越接近測試集數據,即模型準確度 越高。

$$MSE = \frac{1}{n}\Sigma(y_i - \hat{y}_i)^2 \tag{6}$$

B. 決定係數

R²的功能是比較訓練出來的模型與直接使用 平均值當作模型的準確度。R²公式如式(7)所 示,其中<u>y</u>_i為測試集上的數據其輸出平均 值。通常 R^2 會介於0到1之間· $R^2 = 1$ 代表訓 練出來的模型的輸出誤差為0·因此目的是 使模型 R^2 的數值盡量接近1。

$$R^{2} = 1 - \frac{\Sigma(y_{i} - \hat{y}_{i})^{2}}{\Sigma(y_{i} - \bar{y})^{2}}$$
(7)

C. K 折交叉驗證(k-fold cross-validation)

本方法會將整個數據集切割成k個相同 大小的子數據集,接下來會訓練出k個模 型,每次訓練會讓其中一個子數據集作為測 試集,剩下的則會作為訓練集,直到所有的 子數據集都輪流作為測試集後,會將所有模 型的MSE與R²記錄下來,最後計算出其平均 值。使用k折交叉驗證後能更全面的評估模 型的準確度,減少因隨機分割數據造成的偏 差。

(4) 超參數最佳化

隨機森林模型中有兩個超參數的數值是 影響模型準確度最大的因素,其中一個超參 數是估計器數量(n_estimators),代表的是 訓練模型的過程中會產生多少決策樹來計算 結果。另一個是超參數是最大節點層數限制 (max_depth),該參數會決定決策樹最多具 有多少層節點。由於超參數是在訓練模型完 成前給定的數值,而每一種模型其最優數值 都不相同,因此必須針對模型優化超參數的 設定。其中可靠性最高的做法是使用窮舉法,但時間及計算成本過於龐大,因此在實驗中使用了貪婪演算法(greedy algorithm) 來優化這兩個超參數。

本研究實驗中,首先將估計器數量設定 為10,最大節點層數限制設定範圍 10~200,再逐一訓練模組找出可以訓練出 R²最高的10個最大節點層數限制。接著將最 大節點層數限制設定為10,以同樣方式找出 R²最高的10個估計器數量。最後將10個結 果最好的估 計器數量與最大節點層數限制 共100個組合,以5折交叉驗證的方式來訓練 出最好的模型。經過實驗,使用貪婪法花費 的時間相較窮舉法快了41倍以上,節省了大 量的時間成本。

表一為實驗最佳化後的模型參數,在物 理模型參數上,雖然量測模組擷取的光譜範 圍為 375 奈米到 780 奈米,但訓練模型時僅 納入光譜範圍在 450 奈米到 750 奈米之間, 這是由於該波長段的反射率較大的緣故。在 法定深度的範圍時,因為量測的樣本其深寬 比約為 9~12,且實驗中量測的矽通孔主要 為孔徑5微米,所以將模型的深度設定在45 微米到 70 微米之間。而粗糙度與有效面積 在設定時參照過去掃描式電子顯微鏡切片分 析的數值約為 110 奈米與 11.97 %,因此將 粗糙度範圍設定在 110±40 奈米[4],且有 效面積範圍設定在 12±7%。由此決定了物 理模型的輸入光譜範圍與輸出參數範圍。而 在優化隨機森林的超參數時,透過使用貪婪 法與 5 折交叉驗證,將深度、粗糙度、有效 面積比模型的估計器數量分別設定在 199、 161 與 184,且將最大節點層數限制分別設 定在 34、80 與 144 時的模型的精確度最 高,由此決定了最佳化模型的超參數。

物理模型參數						
	波長	深度	粗糙度	有效面積比		
	(奈米)	(微米)	(奈米)	(%)		
實際值	450	45	70	5		
預測值	750	70	150	19		
間距值	1	0.1	1	1		
數據量	301 * 406620					
隨機森林超參數						
超參數	深度		粗糙度	有效面積比		
 估計器數量	199		161	184		
最大節點層數限制	34		80	144		

表一 最佳化參數設定

三、 結果與討論

(1) 模型參數設定與對理論數據的實驗結果 表二為實驗中測試集套用最佳化模型的 結果,在實驗中訓練集為325,296筆數據, 而測試集為81,324筆數據。其中深度測試集 MSE為5.22 · R^2 為0.91 · 粗糙度測試集的 MSE為56.05 · R^2 為0.9 · 而有效面積比測試 集的MSE約為0.06 · R^2 為0.99 。

	深度	粗糙度	有效面積比
MSE	5.22	56.05	0.06
R^2	0.91	0.9	0.99

表二 機器學習對測試集模型參數與結果

(2) 量測模組套用機器學習模型之預測結果

將實際量測矽通孔時得到的光譜套用至 機器學習訓練出來的模型並分別進行3個參 數的驗證,**表三**為實驗中的一組代表性量測 結果。圖六(a)為實際光譜與模型預測結果之 光譜比較圖。量測孔徑約為5微米,pitch約 為10微米,面積比α約為0.31。經掃描式電 子顯微鏡切片驗證的深度實際值為65.08微 米·如圖六 (d)所示·模型預測的數值為 65.49微米·誤差值為 -0.41微米。粗糙度經 掃描式電子顯微鏡切片驗證的實際數值為 110奈米·如圖六 (b)所示·模型預測的數值 為108.66奈米·誤差值為1.34 nm。有效面 積實際數值經掃描式電子顯微鏡切片為 11.97 %·如圖六 (c)所示·模型預測的數值 為11.63 %,誤差值為0.34 %。



圖六 (a) 矽通孔實際量測結果與模型預測結果之光譜比較圖。

(b) (c) (d) 矽通孔經掃描式電子顯微鏡切片後粗糙度、 有效面積比 、深度量測結果。

	深度	粗糙度	有效面積比
	(微米)	(奈米)	(%)
實際值	65.08	110	11.97
預測值	65.49	108.66	11.63
誤差值	-0.41	1.34	0.34

表三 量測光譜套用機器學習模型之預測結果

結論

本研究證實機器學習模型導入反射式光譜干涉量測應用,除了在矽通孔三維結構多參數量 測時有非常高的準確度,同時取代了傳統理論模型迴圈式擬合演算法,更排除了多參數之間交 互影響的痛點,大幅提升量測速度。由於現在製程複雜度越來越高,建構物理模型的成本技術 與越來越高,而審慎訓練完成所建立的機器學習模型,就能在不需複雜演算流程的情況下,藉 由機器學習一步到位快速獲得量測結果,大幅降低了開發及維護成本。機器學習除了矽通孔三 維形貌量測的成功案例之外,亦可應用於先進製程複雜多參數的各種元件量測。未來會在訓練 模型發展的同時,加入一定程度的雜訊及環境變因,使得模型更可以適用於多樣大量的實驗條 件。

參考文獻

- Ku, Y.-S. (2014). Spectral reflectometry for metrology of three-dimensional throughsilicon vias. Journal of Micro/Nanolithography, MEMS, and MOEMS, 13(1), 011209. https://doi.org/10.1117/1.jmm.13.1.011209
- Cheng, X., Tang, Y., Yang, K., & Han, C. (2022). Deep learning for thin film thickness measurement in spectroscopic reflectometry. IEEE Photonics Technology Letters, 34(18), 969–972. https://doi.org/10.1109/lpt.2022.3195997
- 3. Ku, Y.-S., & Yang, F. S. (2010). Reflectometer-based metrology for high-aspect ratio via measurement. Optics Express, 18(7), 7269. https://doi.org/10.1364/oe.18.007269

 Ku, Y.-S., Huang, K. C., & Hsu, W. (2011). Characterization of high density through silicon vias with spectral reflectometry. Optics Express, 19(7), 5993. https://doi.org/10.1364/oe.19.005993

— 作者前分————

周柏文 / 量測中心

顧逸霞 / 量測中心 / 資深正研究員