

經濟部所屬事業機構 109 年新進職員甄試試題

類別：統計資訊

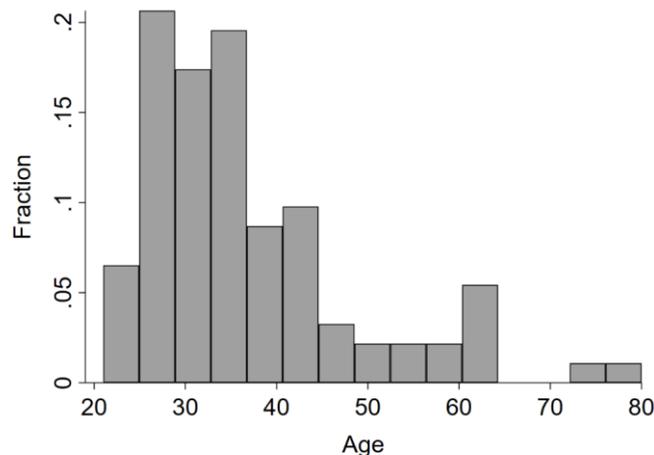
節次：第二節

科目：1. 統計學 2. 巨量資料概論

注意
事項

1. 本試題共 6 頁(含 A3 紙 1 張、A4 紙 1 張)。
2. 可使用本甄試簡章規定之電子計算器。
3. 本試題為單選題共 50 題，每題 2 分，共 100 分，須用 2B 鉛筆在答案卡畫記作答，於本試題或其他紙張作答者不予計分。
4. 請就各題選項中選出最適當者為答案，各題答對得該題所配分數，答錯或畫記多於 1 個選項者，倒扣該題所配分數 3 分之 1，倒扣至本科之實得分數為零為止；未作答者，不給分亦不扣分。
5. 本試題採雙面印刷，請注意正、背面試題。
6. 考試結束前離場者，試題須隨答案卡繳回，俟本節考試結束後，始得至原試場或適當處所索取。
7. 考試時間：90 分鐘。

- [A] 1. 下圖顯示自 1929 年至 2019 年，奧斯卡金像獎最佳女主角得主的(得獎時)年齡分布。根據此圖，得主年齡的平均數與中位數最接近何者？



- (A) 平均數：36；中位數：33
(B) 平均數：33；中位數：36
(C) 平均數：36；中位數：28
(D) 平均數：33；中位數：45

- [A] 2. 某教授蒐集 80 位勞工的資料，將他們的時薪(單位：新臺幣)做為應變數，性別做為自變數，進行迴歸分析。得到結果如下：

	估計值	標準誤
性別	11.8	3.2
常數	160.9	10.5

其中男性勞工的性別值為 1，女性的性別值為 0。若重新定義性別變數，讓男性的性別值為 0，女性的性別值為 1。使用同一樣本估計迴歸模型，得到的常數值和性別係數值，將分別是多少？

- (A) 172.7, -11.8 (B) 172.7, 11.8 (C) 160.9, -11.8 (D) 160.9, 11.8

- [B] 3. 根據一項研究，國道三號中和至土城間的車行時速，大致符合平均 90 公里、標準差 5 公里的常態分配(normal distribution)。該路段設有一台測速照相機，凡超過速限 100 公里視為超速。假設每輛車的速度彼此獨立，請問 3 台車行經該測速照相機，皆無超速的機率最接近下列何者？
- (A) 99 % (B) 93 % (C) 89 % (D) 85 %

[D] 4. 配適一條簡單迴歸模式： $Y_i = \alpha_0 + \alpha_1 X_i + \varepsilon_i$ ，

其中， ε_i 服從平均數為0，標準差為1的常態分配， $i = 1, 2, \dots, 150$ ， $\bar{X} = 150$ ， $\bar{Y} = 85$ ，

$\sum_1^{150} (X_i - \bar{X})^2 = 20$ ， $\sum_1^{150} (Y_i - \bar{Y})^2 = 2000$ ， $\sum_1^{150} (X_i - \bar{X})(Y_i - \bar{Y}) = -180$ 。請問ANOVA表內，MSR為多少？

Source	自由度	SS	MS	F-value	p-value
Model	a	SSR	MSR	F	<0.0001
Error	b	SSE	MSE		
Total	c	2000			

- (A) 16.2 (B) 180 (C) 810 (D) 1620

[A] 5. 變異係數的定義為下列何者？

- (A)標準差/平均數 (B)平均數/標準差 (C)變異數/平均數 (D)平均數/變異數

[C] 6. 1位小兒科醫生，想瞭解2019年台北市新生兒的體重。他從台北市12個行政區隨機抽選3個，然後蒐集該年度3個行政區所有新生兒的體重資料。請問他採用的是何種抽樣方法？

- (A)簡單隨機抽樣(simple random sampling) (B)分層抽樣(stratified sampling)
(C)群集抽樣(cluster sampling) (D)多階段抽樣(multistage sampling)

[C] 7. 某航空公司托運行李收費的政策如下：每位乘客的第1件行李20美金，第2件行李50美金，第3件以上不予載運，且不得協助他人托運行李。假設50%的乘客沒有托運行李，40%的乘客托運1件行李，10%的乘客托運2件行李。1班載有200名乘客的飛機，預期可為航空公司帶來多少行李費收入？

- (A) 2,000美金 (B) 2,600美金 (C) 3,000美金 (D) 5,000美金

[C] 8. 有關型一錯誤(Type I Error)的敘述，下列何者最為正確？

- (A)其機率為1-型二錯誤機率
(B)其機率永遠設為5%
(C)是拒絕真的虛無假設時，所犯的錯誤
(D)是對立假設為真時，不拒絕虛無假設所犯的錯誤

[D] 9. 在多元迴歸模型中，若要進行聯合檢定(joint hypothesis test)，應使用下列何種檢定法？

- (A) t 檢定 (B) Z 檢定 (C)卡方檢定 (D) F 檢定

[A] 10. 指數分配是伽瑪分配的一個特例，當伽瑪分配中的何項參數固定時，伽瑪分配將退化成指數分配？

- (A) $\alpha = 1$ (B) $\alpha = 2$ (C) $\beta = 1$ (D) $\beta = 2$

[B] 11. 小美回到宿舍拿起雜誌翻閱，突然間上個月才更換的燈泡燒毀了！包裝盒上明明寫著可以照亮3,000個小時的燈泡，總共才使用30個小時就燒毀，已知該燈泡的壽命是服從指數分配，請問1,000個使用此品牌燈泡的消費者當中，比小美更倒楣的人約有多少？

- (A)1 (B)10 (C)100 (D)條件不足無法計算

[D] 12. 下列有關變異數分析的敘述，何者有誤？

- (A)每一組資料都必須服從常態分配 (B)每一組資料的母體變異數都必須相同
(C)用以檢定平均數 (D)用以檢定變異數

- [D] 13. 假設隨機變數 X 與 Y 的聯合機率分配為 $f(x, y) = (x + y)/30$, $x = 0, 1, 2, 3$, $y = 0, 1, 2$, 則 $P(x > y)$ 為下列何者?
 (A) 0 (B) 1/2 (C) 2/3 (D) 3/5
- [B] 14. 公司舉辦健行活動, 某員工去程平均時速為6公里, 回程平均時速為3公里, 則該員工的總平均時速為下列何者?
 (A) 3.5公里 (B) 4公里 (C) 4.5公里 (D) 5公里
- [C] 15. 就同一組資料進行假設檢定時, 下列敘述何者有誤?
 (A) 右尾檢定和左尾檢定所計算出來的檢定統計量相同
 (B) 單尾檢定和雙尾檢定所計算出來的檢定統計量相同
 (C) 右尾檢定和左尾檢定所計算出來的p值相同
 (D) 右尾檢定和左尾檢定所計算出來的p值和為1
- [C] 16. 某公司販賣的10公克果醬包, 根據過去的資料顯示其重量的標準差為0.2公克, 今任取1包該公司販賣的10公克果醬包, 其重量介於9.6公克到10.4公克之間的機率至少為下列何者?
 (A) 1/2 (B) 2/3 (C) 3/4 (D) 4/5
- [D] 17. 1磅精心調配的綜合咖啡豆當中包含了非洲、美洲、亞洲等3地生產的咖啡豆, 假設 X 與 Y 分別代表這1磅的綜合咖啡豆之中非洲豆和美洲豆的重量, 已知 X 與 Y 的聯合機率密度函數為 $f(x, y) = 24xy$, $0 < x < 1$, $0 < y < 1$, $x + y < 1$ 。若非洲豆的重量為0.75磅, 試問美洲豆重量小於0.1磅的機率為下列何者?
 (A) 1/25 (B) 2/25 (C) 3/25 (D) 4/25
- [A] 18. 從台灣全省抽樣1,000家公司, 調查其去年的業績, 發現結果如下: 業績成長的有150家, 業績衰退的有550家, 業績不變的有300家, 而其中服務業所佔的比例分別為45%, 30%, 50%。若從中選取1家公司, 其為服務業的機率為下列何者?
 (A) 0.3825 (B) 0.4016 (C) 0.4167 (D) 0.4207
- [B] 19. 令 (X_1, X_2, X_3) 為由常態母體 $N(\mu, \sigma^2)$ 抽出的一組隨機樣本, T_1, T_2, T_3, T_4 均為 μ 的估計量, $T_1 = (3X_1 + 3X_2 + 4X_3)/10$, $T_2 = (X_1 + X_2 + X_3)/3$, $T_3 = (X_1 + 2X_2 + 3X_3)/6$, $T_4 = (2X_1 + 3X_2 + 4X_3)/9$, 請問下列何者為 μ 的不偏估計量中變異數最小者?
 (A) T_1 (B) T_2 (C) T_3 (D) T_4
- [D] 20. 棒球教練想要透過假說檢定確認某選手的打擊率是否超過3成, 乃蒐集過去50次的打擊紀錄做為樣本, 得到的打擊率為0.33。假設該選手的每次打擊都是獨立事件, 請問在設定顯著水準為5%的條件下, p值(p-value)係指下列何種機率值?
 (A) 0.05 (B) $\Pr(Z > 1.645)$
 (C) $\Pr(\text{樣本打擊率} > 0.3 \mid \text{真實打擊率} = 0.3)$ (D) $\Pr(\text{樣本打擊率} > 0.33 \mid \text{真實打擊率} = 0.3)$
- [D] 21. 已知某股票的報酬率服從期望值為 μ , 標準差為 σ 的對數常態分配, 則該股票報酬率的期望值為下列何者?
 (A) μ (B) e^μ (C) $e^{\frac{\mu + \sigma^2}{2}}$ (D) $e^{\mu + \frac{\sigma^2}{2}}$
- [C] 22. 為了解台灣人民的網路使用情形, 隨機抽取600位年滿15歲以上的國民調查, 其中有360位每天都使用網路, 據此估計台灣15歲以上的國民每天使用網路的比率為0.6, 則在信賴係數(信心水準)為95%時, 估計誤差之最大值為下列何者? ($Z_{0.05} = 1.645$, $Z_{0.025} = 1.96$)
 (A) 0.0200 (B) 0.0337 (C) 0.0392 (D) 0.0475
- [A] 23. 已知 \bar{X} 服從常態分配 $N(\mu, \sigma)$, 設 μ 的95%信賴區間為 (L_1, U_1) , μ 的90%信賴區間為 (L_2, U_2) , 下列敘述何者正確?
 (A) $L_1 < L_2 < U_2 < U_1$ (B) $L_2 < L_1 < U_2 < U_1$ (C) $L_1 < L_2 < U_1 < U_2$ (D) $L_2 < L_1 < U_1 < U_2$

- [B] 24. 為了解房屋售價(X)與面積(Y)之間的關係，隨機選取12戶已成交房屋，所得資料為 $\sum_{i=1}^{12} x_i = 3177$ 、 $\sum_{i=1}^{12} y_i = 272$ 、 $\sum_{i=1}^{12} x_i^2 = 869111$ 、 $\sum_{i=1}^{12} y_i^2 = 6464$ 、 $\sum_{i=1}^{12} x_i y_i = 74113$ ，X與Y的相關係數為下列何者？
 (A) 0.68 (B) 0.73 (C) 0.82 (D) 0.89
- [D] 25. 二個互斥事件A、B，機率分別是0.5、0.6，則 $\Pr \{ A^c \cup B^c \}$ 的值為何？(註： A^c 、 B^c 分別表示A、B的餘集合)
 (A) 0.7 (B) 0.8 (C) 0.9 (D) 1.0
- [C] 26. 下列何者不是Apache Hadoop之特色？
 (A)使用MapReduce程式框架
 (B)支援Java語言
 (C) Apache Mahout是一種用來支援Apache Hadoop分散式工作程序管理的程式庫
 (D)使用Hadoop Distributed File System
- [C] 27. 對於HDFS Shell指令，下列敘述何者有誤？
 (A) Hadoop fs -ls用來列出HDFS檔案與目錄列表
 (B) Hadoop fs -rm input/masters刪除HDFS上的檔案
 (C) Hadoop fs -cat input/slaves壓縮HDFS內之檔案
 (D) Hadoop fs -put conf input將本地端檔案上傳至HDFS
- [B] 28. 對於k-均值(k-means)聚類演算法的敘述，下列何者有誤？
 (A) k-均值中update的程序，將更新聚類中心
 (B) k-均值中assign的程序，將比較各資料點之間的距離，並將各資料點以隨機方式分配至其中一個聚類
 (C) k-均值中的k值表示資料將分成幾類，需事先給定
 (D)每一次執行的k-均值演算法，其結果可能會不一樣
- [A] 29. 對於NoSQL資料庫說明，下列何者有誤？
 (A)可採用Key-DM資料架構來建立資料庫 (B)使用記憶體方式建立分散資料庫
 (C) MongoDB是一種NoSQL的資料庫 (D)各種NoSQL資料庫所支援的語言可能不同
- [C] 30. 對監督式學習(supervised learning)的說明，下列何者有誤？
 (A)監督式學習需要使用標記過類別的資料(labeled data)進行訓練(training)
 (B)監督式學習可以跟非監督式學習整合，進行資料分析
 (C)目前所有的監督式學習的方法，皆無法對線性不可分(nonlinear)的資料進行分類
 (D)將資料的所有特徵(feature)放入監督式學習，不一定會找到最好的分類方式
- [D] 31. 以機器學習對於巨量資料進行分析後，通常會使用混淆矩陣(confusion matrix)，對於所產生的分類器進行評估，其中將分析結果分為true positive (TP)、true negative (TN)、false positive (FP)及false negative (FN)，下列敘述何者有誤？
 (A)正確率Accuracy = $(TP + TN) / (TP + TN + FP + FN)$
 (B)召回率Recall = $TP / (TP + FN)$
 (C)精確率Precision = $TP / (TP + FP)$
 (D) F1 Score = $TP / (TP + FP + FN)$
- [A或D] 32. 對於大量資料分析的技術，下列敘述何者有誤？
 (A) PageRank是用來對於數值資料進行資料壓縮的演算法
 (B)支持向量機(support vector machine)的核函式(kernel function)選擇會影響分析結果
 (C) k-最近鄰居(k-nearest neighbors)是用來對於資料分類的監督式演算法
 (D) k-中心點(k-medoids)是用來對於資料分類的非監督式演算法

- [A] 33. 使用MapReduce框架來設計一個字數統計(word count)程式，其程式所進行的常用標準程序應為下列何者？
- (A) Input → Splitting → Mapping → Shuffling → Reducing → Final Result
 (B) Input → Mapping → Splitting → Shuffling → Reducing → Final Result
 (C) Input → Mapping → Splitting → Reducing → Shuffling → Final Result
 (D) Input → Reducing → Splitting → Shuffling → Mapping → Final Result
- [B] 34. CAP定理可用來分析NoSQL資料庫的特性，下列對於NoSQL資料庫及CAP定理之敘述，何者有誤？
- (A) CAP定理的「C」代表的是一致性(consistency)性質
 (B) CAP定理的「A」代表的是原子性(atomicity)性質
 (C) CAP定理的「P」代表的是分區容錯(partition tolerance)性質
 (D) NoSQL資料庫輸出內容，可以搭配非監督式演算法進行資料探勘分析
- [A] 35. 下列工作何者適合在一般資料庫進行，但不適合在NoSQL環境？
- (A)維持保證多方同時交易一致性的管理機制(concurrency control)
 (B)複雜度高的加總計算
 (C)有時效性的趨勢分析
 (D)綱要(schema)尚未穩定的彈性分散式資料儲存與擷取
- [A] 36. 下列何種計算方法原則是先綜觀全局，再分層深化處理的廣度優先策略？
- (A) Apriori原則找所有frequent patterns (B) FP-growth計算association rules
 (C) Agglomerative hierarchical clustering (D) MapReduce
- [D] 37. 對關聯規則(association rule) $X \rightarrow Y$ 的理解，下列何者較為正確？
- (A) X的值決定Y的值 (B) X是因，Y是果
 (C) X之後的下一階段是Y (D) X出現時，也容易見到Y
- [B] 38. 文字探勘(text mining)常見的TF-IDF處理，IDF是以甚麼為單位的值？(Document--D代表文件，Term--T代表字詞，Weight--W代表加權比重)
- (A) IDF (D, W) (B) IDF (T) (C) IDF (T, D) (D) IDF (W)
- [C] 39. 下列何者為公有區塊鏈(block-chain)的特性？
- (A)由鏈外仲裁者驗證資料 (B)由認證金融組織負責Bitcoin(比特幣)運作
 (C)已上鏈資料無法更改 (D)不支援智能合約的數位服務
- [C] 40. 有關巨量資料的多類(variety)特性，下列敘述何者正確？
- (A)一般感知器(sensor)所回傳的資料為無結構性資料(unstructured data)
 (B)監視器所錄下的視訊(video)為半結構性資料(semi-structured data)
 (C)線上訂房的網頁資料為半結構性資料(semi-structured data)
 (D)書籍文本文字(text)為結構性資料(structured data)
- [B] 41. 關於Hadoop分散式檔案系統HDFS的檔案文件儲存，下列敘述何者有誤？
- (A)檔案內容將被切割為區塊(chunk)儲存
 (B)檔案區塊大小不一，視檔案內容而定
 (C)檔案區塊大小通常為64 MB以上
 (D)每一檔案區塊至少將會複製二份存放

- [A] 42. 資料倉儲設計會希望是主題導向(subject-oriented)，下列敘述何者正確？
 (A)主題不應被期待在倉儲系統運作後自然浮現
 (B)分析維度的準備與主題制定是分別獨立的设计工作
 (C)資料倉儲設計不易，最好盡量納入多元主題
 (D)主題需要經常性的檢討並重新訂定
- [C] 43. 資料立方(data cube)是由資料倉儲綱要所建立的多維度數值統計資訊，若決策者希望獲得某單一維度的部分條件之統計量來分析資料時，可以用下列何種 OLAP 的運算來達成？
 (A) roll up (B) drill down (C) slice (D) dice
- [D] 44. 對Hadoop Distributed File System (HDFS)的敘述，下列何者有誤？
 (A)提供容錯功能 (B)至少包含一台data node
 (C)至少包含一台name node (D)至少包含一台analytics node
- [C] 45. 有關MapReduce程式的執行，下列敘述何者正確？
 (A)工作追蹤器(job tracker)主要是回報資料節點中 Map 或 Reduce 任務的執行情況
 (B)主節點(master node)若發生故障，只有主節點上的任務(task)會失敗
 (C)資料節點(data node)若發生故障，該節點的任務(task)將會重新指定給其他資料節點
 (D)為獲取最大的平行計算效益，Map任務和Reduce任務不會安排至在同一資料節點上執行
- [B] 46. 以資料分析為目的構建資料倉儲(Data Warehouse)時，其資料特性將不包括下列何者？
 (A)主題導向性(subject-oriented) (B)資料異動性(volatile)
 (C)多重整合性(integrated) (D)時間變動性(time variant)
- [B] 47. 當在具有數值屬性(numerical attribute)的資料集中探勘關聯式規則(association rule)時，必須預先對屬性資料完成何種處理？
 (A)補值處理(missing value imputation) (B)離散化(discretization)
 (C)比例轉換(scaling) (D)正規化(normalization)
- [B] 48. 巨量資料分析前進行屬性特徵選擇(Feature-Selection)時，下列何種方法不適合用來做為選擇的標準依據？
 (A)資訊增益(Information Gain) (B)均方根誤差(Root Mean Squared Error)
 (C)卡方係數(Chi-Squared coefficient) (D)相關係數(Pearson's correlation coefficient)
- [A] 49. 深度神經網路(deep neural networks)的神經元中通常輸出時會經過激發函數(activation function)的轉換，下列針對常用激發函數的敘述何者有誤？
 (A) ReLU可以避免過度擬合(overfit)的問題
 (B) Sigmoid會有梯度消失(vanishing gradient)的問題
 (C) ReLU會發生死亡神經元(dead neural)的問題
 (D) Sigmoid會有梯度爆炸問題(vanishing gradient)的問題
- [D] 50. 集成式分類方法是將弱分類器(weak classifiers)集合起來用以增強分類的準確率與穩定度。請問下列何者不是集成式分類方法？
 (A) AdaBoost (B) Gradient Boosted Trees
 (C) Random Forest (D) K-Nearest Neighbor