

HDA


Advanced Health Data Analytics: A Statistical Deep Dive

Leveraging Regression & Inference for Healthcare Research

تحليلات البيانات الصحية المتقدمة: الغوص الإحصائي
استخدام الانحدار والاستدلال الإحصائي في أبحاث الرعاية الصحية

The Core Challenge in Health Research

- **Ideal World (RCTs):** Randomize patients into treatment and control groups. This is the gold standard for establishing causality (e.g., drug trials).
- **Real World (Observational Data):** We often analyze pre-existing data where assignment was **not** random (e.g., patients who chose a surgery vs. those who didn't, EHR data).
- **The Fundamental Problem:** How do we isolate the effect of a treatment or exposure (X) on a health outcome (Y) from other influencing factors (confounders)?



التحدي الأساسي في أبحاث الصحة

- العالم المثالي (RCTs - التجارب العشوائية المحكمة): نقوم بتوزيع المرضى بشكل عشوائي بين مجموعة علاج ومجموعة ضابطة. هذا هو المعيار الذهبي لإثبات السببية (مثل تجارب الأدوية).
- العالم الواقعي (البيانات الرصدية): نحلل بيانات موجودة مسبقًا حيث التوزيع لم يكن عشوائيًا (مثل: مرضى اختاروا عملية جراحية مقابل آخرين لم يختاروها، بيانات السجلات الطبية الإلكترونية EHR).
- المشكلة الأساسية: كيف نعزل تأثير العلاج أو التعرض (X) على النتيجة الصحية (Y) عن تأثير عوامل أخرى مربكة (confounders)?

The Essential Tool: Linear Regression

الأداة الأساسية: الانحدار الخطي (Linear Regression)

• الهدف: نمذجة العلاقة الخطية بين متغير تابع (Y - النتيجة) ومتغير أو أكثر مستقل (X - العوامل المتنبئة).

- **Purpose:** To model the linear relationship between a dependent (outcome) variable and one or more independent (predictor) variables.

متغير تابع
Y
متغير مستقل
X

- **The Core Equation:** $Y = \beta_0 + \beta_1 X_1 + \varepsilon$

- **Y: Health Outcome** (e.g., HbA1c level, length of hospital stay, patient satisfaction score)
- **X₁: Primary Predictor** (e.g., drug dosage, type of surgical procedure, exposure to a pollutant)
- **β_1 : Regression Coefficient:** The estimated change in the outcome Y for a one-unit change in X_1 , holding other factors constant.
- **β_0 : Y-Intercept:** The expected value of Y when all predictors are zero.
- **ε : Error Term:** The part of the outcome not explained by the model (residual).

independent
predictor

dependent
outcome



$$Y = \beta_0 + \beta_1 X + \varepsilon$$

خط تقاطع
خط انحدار

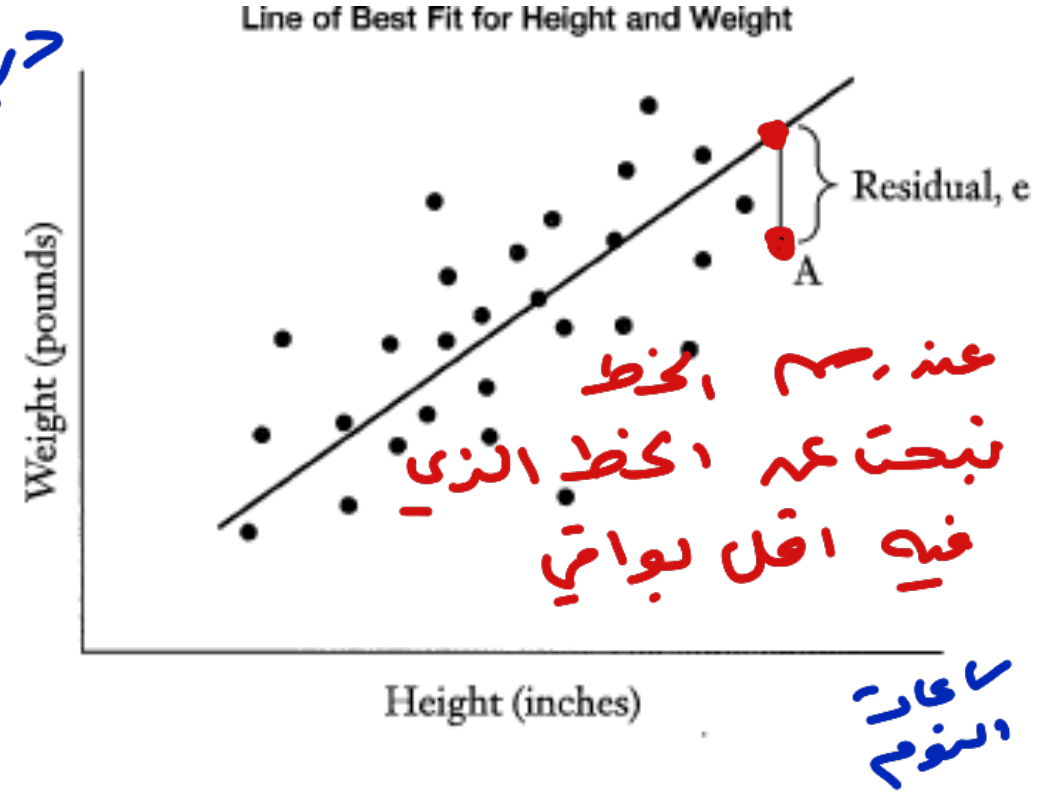
$Y = 50 + 2X$
العلاقة بين ساعات النوم X ودرجة الحموضة Y
 $\beta_0 = 50$ $\beta_1 = 2$

- Y: النتيجة الصحية (مثل: مستوى HbA1c، مدة البقاء بالمستشفى).
- X₁: المتغير المستقل (مثل: جرعة دواء، نوع العملية، التعرض لمُلوث).
- β_1 : معامل الانحدار - مقدار التغير في Y عند زيادة X بوحدة واحدة (مع تثبيت باقي المتغيرات).
- β_0 : نقطة التقاطع (Intercept) - قيمة Y المتوقعة عندما تكون جميع $X = 0$.
- ε : الخطأ - الجزء من Y الذي لا يفسره النموذج.

Finding the "Line of Best Fit"

- The goal is to find the line that minimizes the sum of squared residuals (SSR).
- Residual (ϵ) = Observed Y - Predicted Y (\hat{Y})
- A smaller SSR indicates a model that more accurately predicts the observed data. This method is known as Ordinary Least Squares (OLS) estimation.

خط أفضل



إيجاد "أفضل خط" (Line of Best Fit)

- الهدف: إيجاد الخط الذي يقلل مجموع مربعات الأخطاء (SSR).
- الباقي (ϵ Residual): الفرق بين القيمة المرصودة Y والقيمة المتوقعة \hat{Y} .
- طريقة المربعات الصغرى (OLS) هي الأداة الأساسية لحساب ذلك.

Interpreting Key Outputs for Clinical Insight

- **Coefficient (β_1):** The effect size.

- Example: For X_1 (Drug Dosage in mg) and Y (LDL Cholesterol in mg/dL), $\beta_1 = -0.8$ means that for each additional 1mg of the drug, LDL is expected to decrease by 0.8 mg/dL, *ceteris paribus*.

$$y = \beta_0 + \beta_1 x$$
$$y = -0.8x$$

↓ ↑

- **P-value:** Tests the null hypothesis ($H_0: \beta_1 = 0$). A low p-value (< 0.05) provides evidence that the observed effect is statistically significant and unlikely due to random chance.

- **Confidence Interval (CI):** A 95% CI for β_1 provides a range of plausible values for the true effect size. If the CI does not include 0, the effect is significant at the 5% level.

100!
↙ ↘
95% 5!

- **R^2 (R-squared):** The proportion of variance in the outcome variable that is explained by the model. An R^2 of 0.30 means 30% of the variation in the health outcome is accounted for by the predictors.

$$Y$$
$$30\% = 0.3$$
$$R^2 = 40\%$$

X

تفسير المخرجات في السياق السريري

- المعامل β_1 : يمثل حجم التأثير.
- مثال: إذا كان X = جرعة دواء (ملغ) و Y = مستوى الكوليسترول LDL (ملغ/ديسيلتر)، ووجدنا $\beta_1 = -0.8$ فهذا يعني: كل زيادة 1 ملغ من الدواء تقلل LDL بمقدار 0.8 ملغ/ديسيلتر (مع ثبات العوامل الأخرى).
- القيمة الاحتمالية (P-value): تختبر الفرضية الصفرية $H_0: \beta_1 = 0$. إذا كانت $0.05 > p$ ⇒ النتيجة مهمة إحصائيًا.
- فترة الثقة (CI): نطاق للقيمة الحقيقية لـ β_1 . إذا لم يتضمن 0 ⇒ التأثير مهم.
- معامل التحديد R^2 : نسبة التباين في Y المفسر بواسطة النموذج. مثال: $R^2 = 0.30 \Rightarrow 30\%$ من الاختلاف في النتيجة يفسره المتغيرات.

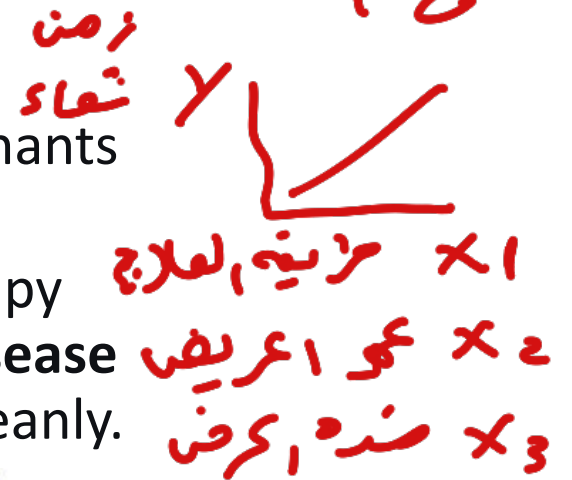
The Power of Multiple Regression

قوة الانحدار المتعدد (Multiple Regression)



- The Extended Equation: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \varepsilon$
- This is the key to solving the confounding problem. It allows us to statistically "control for" other variables.
- Health Example:
 - We want to study the effect of X_1 (New Therapy) on Y (Recovery Time).
 - X_2 (Patient Age) and X_3 (Disease Severity Index) are also major determinants of recovery time.
 - By including X_2 and X_3 in the model, the coefficient β_1 for the new therapy represents its effect **after accounting for the differences in age and disease severity** between the groups. This isolates the therapy's effect more cleanly.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4 + \varepsilon$$



• الهدف: التحكم إحصائيًا في المتغيرات المربكة (Confounders).

• مثال صحي: ندرس تأثير علاج جديد (X_1) على زمن الشفاء (Y).

• X_2 = عمر المريض.

• X_3 = شدة المرض.

• بإدخال X_2 و X_3 في النموذج، يصبح β_1 معبرًا عن تأثير العلاج بعد ضبط أثر العمر وشدة المرض.

A Critical Threat: Omitted Variable Bias

- **Definition:** Bias that occurs when a variable that is a common cause of both the independent and dependent variable is left out of the model.
- **Consequence:** The estimated effect of your primary predictor (β_1) is **biased and misleading**.
- **Clinical Example:** You find that Coffee Consumption (X_1) predicts Heart Disease (Y). But if you fail to control for Smoking Status (Z), your estimate for coffee is biased because smokers often drink more coffee *and* have higher heart disease risk. The model wrongly attributes smoking's effect to coffee.

تهديد خطير: تحيز المتغير المحذوف (Omitted Variable Bias)

- يحدث عند حذف متغير يؤثر على X و Y معًا.
- النتيجة: تقدير β_1 يكون متحيزًا ومضللًا.
- مثال: استهلاك القهوة (X_1) مرتبط بأمراض القلب (Y). إذا لم نتحكم في التدخين (Z) سيكون التقدير خاطئ لأن التدخين يزيد استهلاك القهوة ويرفع خطر أمراض القلب.

Essential Regression Assumptions (IV&V)

- 1.Linearity:** The relationship between X and Y is linear. (Check with scatterplots).
- 2.Independence:** Observations are independent of each other (e.g., not repeated measures on the same patient without adjustment).
- 3.Homoscedasticity:** The variance of the errors is constant across all values of X. (Check with Residual vs. Fitted plot).
- 4.Normality:** The residuals (errors) are approximately normally distributed. (Check with Q-Q plot).
- 5.No Perfect Multicollinearity:** Predictor variables are not perfectly correlated with each other (e.g., don't include both "weight in kg" and "weight in lbs").

افتراضات أساسية للانحدار

1. الخطية (Linearity): العلاقة بين X و Y خطية.
2. الاستقلالية (Independence): الملاحظات مستقلة (ليست قياسات مكررة لنفس المريض).
3. تجانس التباين (Homoscedasticity): تباين الأخطاء ثابت عبر قيم X.
4. التوزيع الطبيعي (Normality): البواقي (Residuals) تتبع توزيعًا طبيعيًا تقريبيًا.
5. عدم وجود ارتباط كامل (No Perfect Multicollinearity): المتغيرات المستقلة ليست مرتبطة ارتباطًا تامًا (مثل وزن بالكيلوغرام والباوند معًا).

Correlation vs. Regression in Health Context

Feature	Correlation (r)	Regression (β)
What it measures	Strength & direction of a linear relationship	Size and direction of an effect
Range	-1 to +1	$-\infty$ to $+\infty$
Units	Unitless	Expressed in units of Y / units of X
Key Question	"Are these two variables associated?"	"How much does Y change for a unit change in X?"
Causality	Never implies causation	Can support causal inference if design is strong (e.g., controls for confounders)

Correlation vs. Regression in Health Context

الفرق بين الارتباط والانحدار (Correlation vs. Regression)

الخاصية	الارتباط (r)	الانحدار (β)
ما يقيسه	قوة واتجاه العلاقة	حجم واتجاه التأثير
النطاق	-1 إلى +1	-∞ إلى +∞
الوحدات	بلا وحدات	بوحدات $Y \div X$
السؤال الرئيسي	هل يوجد ارتباط بين متغيرين؟	كم يتغير Y إذا تغير X بوحدة واحدة؟
السببية	لا يعني السببية	يمكن أن يدعم السببية إذا كان التصميم قويًا ويضبط العوامل المربكة

Conclusion: From Data to Decisions

- Regression analysis is the workhorse of modern health services research, epidemiology, and outcomes research.
- It transforms raw, observational data from EMRs, claims, and surveys into **evidence**.
- The validity of this evidence hinges on **robust model specification**(including the right controls) and **rigorous testing of assumptions**.
- When applied correctly, it empowers healthcare administrators and clinicians to evaluate interventions, assess risk factors, and ultimately, improve patient care and resource allocation

الخلاصة: من البيانات إلى القرارات

- يُعَدُّ تحليل الانحدار الأداة الأساسية في أبحاث خدمات الصحة الحديثة، وعلم الأوبئة، وأبحاث النتائج.
- فهو يحوّل البيانات الخام والرصدية من السجلات الطبية الإلكترونية، والمطالبات، والاستبيانات إلى أدلة.
- وتعتمد صحة هذه الأدلة على دقة بناء النموذج (بما في ذلك اختيار الضوابط المناسبة) والاختبار الصارم للافتراضات.
- وعند تطبيقه بشكل صحيح، يمكن هذا التحليل مسؤولي الرعاية الصحية والأطباء من تقييم التدخلات، وتحديد عوامل الخطر، وفي النهاية تحسين رعاية المرضى وتوزيع الموارد.

1. في نموذج انحدار يتنبأ ضغط الدم الانقباضي للمريض (Y) بناءً على تناول الصوديوم (X)، فإن معامل $(\beta_1) = 2.5$ يُفسّر بأنه:

(a) ارتباط موجب قوي بين الصوديوم وضغط الدم.

(b) لكل زيادة بمقدار وحدة واحدة في تناول الصوديوم، يُتوقع أن يزيد ضغط الدم بمقدار 2.5 وحدة مع تثبيت العوامل الأخرى. ✓

(c) يفسّر الصوديوم 2.5% من تباين ضغط الدم.

(d) العلاقة دالة إحصائياً بقيمة p تساوي 2.5.

2. الطريقة الإحصائية الأساسية لإيجاد خط الانحدار الأفضل في الانحدار الخطي هي:

(a) تعظيم قيمة R^2 .

(b) تقليل مجموع مربعات البواقي (SSR). ✓

(c) ضمان أن البواقي موزعة طبيعياً.

(d) حساب معامل الارتباط.

3. ميزة أساسية للانحدار المتعدد مقارنة بالانحدار الخطي البسيط في بحوث الصحة هي قدرته على:

(a) إثبات السببية من بيانات رصدية.

(b) التحكم في العوامل المربكة (Confounders). ✓

(c) ضمان أن المتغير التابع يتبع التوزيع الطبيعي.

(d) إثبات صحة الفرضية.

4. يحدث تحيز المتغير المهمّل (Omitted Variable Bias) عندما:

(a) يكون حجم العينة صغيراً جداً.

(b) تكون قيمة p أكبر من 0.05.

(c) يُستبعد متغير ذو صلة يؤثر في كليّ من المتنبئ والنتيجة. ✓

(d) تكون العلاقة بين المتغيرات غير خطية.

5. إذا كان فاصل الثقة 95% لمعامل انحدار ما بين 1.2 و 3.8، فالتفسير الصحيح هو:

(a) النتيجة ليست دالة إحصائياً.

(b) نحن واثقون بنسبة 95% أن الأثر الحقيقي في المجتمع يقع بين 1.2 و 3.8. ✓

(c) هناك احتمال 5% بأن الفرضية الصفرية صحيحة.

(d) قيمة R^2 تساوي 0.95.

6. تشير قيمة R^2 في نموذج الانحدار إلى:

(a) الدلالة الإحصائية للمتنبئات.

(b) احتمال أن يكون النموذج صحيحاً.

(c) نسبة التباين في المتغير التابع المفسّرة بواسطة النموذج. ✓

(d) قوة الارتباط بين كل متنبئ والنتيجة.

7. أي مما يلي ليس افتراضاً قياسيًّا للانحدار الخطي؟

(a) تجانس التباين (Homoscedasticity).

(b) طبيعية البواقي.

(c) وجود تعدد ترابط (Multicollinearity) بين المتنبئات. ✓

(d) علاقة خطية بين المتغيرات المستقلة والتابعة.

8. قيمة $p = 0.03$ لمعامل انحدار تعني:

- (a) يوجد احتمال 3% أن الفرضية الصفرية صحيحة.
- (b) المعامل ذو أهمية سريرية.
- (c) هناك احتمال 3% لملاحظة مثل هذا الأثر (أو أكبر) إذا كانت الفرضية الصفرية صحيحة. ☒
- (d) حجم الأثر كبير جداً.

9. في الرعاية الصحية، تأتي البيانات الرصدية المستخدمة في تحليلات الانحدار غالباً من:

- (a) التجارب العشوائية المحكمة فقط (RCTs).
- (b) السجلات الطبية الإلكترونية (EMRs) وبيانات المطالبات التأمينية. ☒
- (c) تجارب مخبرية مضبوطة تماماً.

(d) مجموعة مرضى واحدة متجانسة تماماً.

10. ماذا يمثل حد الخطأ (ε) في معادلة الانحدار؟

- (a) الفرق بين القيم المتوقعة والملاحظة للمتغير التابع (الباقى). ☒
- (b) تأثير المتغير المستقل.
- (c) الجزء المقطوع (Intercept) للنموذج.
- (d) معامل الارتباط.

(مفهوماً ε هو الجزء غير المفسر من Y؛ وفي العينة يقابله الباقي Residual).

11. إذا كان هناك ترابط عالٍ جداً بين متنبئين (مثل "الوزن" و"مؤشر كتلة الجسم BMI") فهذا يخرق افتراض:

- (a) تجانس التباين.
- (b) الطبيعية.
- (c) عدم وجود تعدد ترابط تام (No perfect multicollinearity). ☒
- (d) الاستقلالية.

12. مخطط البواقي الذي يُظهر تبعثراً عشوائياً حول الصفر يشير إلى:

(a) انتهاك افتراض الخطية.

(b) تحقق افتراض تجانس التباين على الأرجح. ✓

(c) وجود تحيز متغير مُهمَل.

(d) أن قيمة R^2 عالية.

13. الارتباط (r) وميل الانحدار (β) مرتبطان، لكن الفرق الأساسي هو أن:

(a) فقط الارتباط يمكن أن يكون سالبًا.

(b) ميل الانحدار يقدّم تقديراً لمقدار التغيّر (حجم الأثر). ✓

(c) لا يُستخدم الانحدار إلا مع المتغيرات المستمرة.

(d) يحتاج الارتباط إلى حجم عينة أكبر.

14. السبب الرئيسي لكون التوزيع العشوائي في RCT يقلّل التشويش (Confounding) هو أنه:

(a) يضمن حجم عينة كبير.

(b) يجعل المجموعات متكافئة — في المتوسط — في العوامل المشاهدة وغير المشاهدة. ✓

(c) يجعل تحليل الانحدار غير ضروري.

(d) يزيل خطأ القياس.

15. في النموذج:

$$\text{مدة البقاء بالمستشفى} = \beta_0 + \beta_1(\text{نوع الجراحة}) + \beta_2(\text{العمر}) + \epsilon,$$

يمثل β_1 :

(a) الارتباط بين نوع الجراحة والعمر.

(b) أثر نوع الجراحة على مدة البقاء بعد أخذ اختلافات العمر بالحسبان. ✓

(c) أثر العمر على مدة البقاء بعد أخذ نوع الجراحة بالحسبان.

(d) متوسط مدة البقاء الكلي.

MCQs

- **1. In a regression model predicting patient systolic blood pressure (Y) based on sodium intake (X), a coefficient (β_1) of 2.5 would be interpreted as:**
 - a) A strong positive correlation between sodium and blood pressure.
 - ☒ b) For every 1-unit increase in sodium intake, blood pressure is expected to increase by 2.5 units, holding other factors constant.
 - c) Sodium intake explains 2.5% of the variation in blood pressure.
 - d) The relationship is statistically significant with a p-value of 2.5.

- **2. The primary statistical method used to find the line of best fit in linear regression is:**
 - a) Maximizing the R-squared value.
 - b) Minimizing the sum of squared residuals.
 - c) Ensuring the residuals are normally distributed.
 - d) Calculating the correlation coefficient.
- **3. A key advantage of multiple regression over simple linear regression in health research is its ability to:**
 - a) Establish causation from observational data.
 - b) Control for confounding variables.
 - c) Guarantee a normal distribution of the outcome variable.
 - d) Prove a hypothesis is true.

- **4. Omitted variable bias occurs when:**

- a) The sample size is too small.
- b) The p-value is greater than 0.05.
- c) A relevant variable that affects both the predictor and outcome is left out of the model.
- d) The relationship between variables is non-linear.

- **5. If a 95% confidence interval for a regression coefficient ranges from 1.2 to 3.8, what is the correct interpretation?**

- a) The result is not statistically significant.
- b) We are 95% confident the true population effect lies between 1.2 and 3.8.
- c) There is a 5% chance the null hypothesis is true.
- d) The R-squared value is 0.95.

- **6. The R-squared value in a regression model indicates:**
 - a) The statistical significance of the predictors.
 - b) The probability that the model is correct.
 - c) The proportion of variance in the outcome explained by the model.
 - d) The strength of the correlation between each predictor and the outcome.

- **7. Which of the following is NOT a standard assumption of linear regression?**
 - a) Homoscedasticity
 - b) Normality of residuals
 - c) Multicollinearity between predictors
 - d) Linear relationship between independent and dependent variables

- **8. A p-value of 0.03 for a regression coefficient suggests:**
 - a) There is a 3% probability the null hypothesis is true.
 - b) The coefficient is clinically significant.
 - c) There is a 3% chance of observing such an effect if the null hypothesis were true.
 - d) The effect size is very large.

- **9. In healthcare, observational data for regression analysis often comes from:**
 - a) Only randomized controlled trials (RCTs).
 - b) Electronic medical records (EMRs) and claims data.
 - c) Perfectly controlled laboratory experiments.
 - d) A single, homogenous patient group.

- **10. What does the error term (ϵ) in the regression equation represent?**

- a) The difference between the predicted and observed values of the outcome.
- b) The effect of the independent variable.
- c) The y-intercept of the model.
- d) The correlation coefficient.

- **11. If two predictor variables (e.g., "weight" and "BMI") are extremely highly correlated, it violates the assumption of:**

- a) Homoscedasticity
- b) Normality
- c) No perfect multicollinearity
- d) Independence

- **12. A residual plot that shows a random scatter of points around zero indicates:**
 - a) The assumption of linearity is violated.
 - ☒ b) The assumption of homoscedasticity is likely met.
 - c) The model has omitted variable bias.
 - d) The R-squared value is high.

- **13. Correlation (r) and regression slope (β) are related, but a key difference is:**
 - a) Only correlation can be negative.
 - ☒ b) The regression slope provides an estimate of the magnitude of change.
 - c) Only regression can be used with continuous variables.
 - d) Correlation requires a larger sample size.

- **14. The primary reason random assignment in an RCT minimizes confounding is that it:**

- a) Guarantees a large sample size.
- ☒ b) Ensures the groups are equivalent, on average, on both observed and unobserved factors.
- c) Makes regression analysis unnecessary.
- d) Eliminates measurement error.

- **15. In the model $\text{Hospital Stay} = \beta_0 + \beta_1(\text{Surgery Type}) + \beta_2(\text{Age}) + \epsilon$, the coefficient β_1 represents:**

- a) The correlation between surgery type and age.
- ☒ b) The effect of surgery type on hospital stay, after accounting for differences in patient age.
- c) The effect of age on hospital stay, after accounting for surgery type.
- d) The overall average hospital stay.