

MEDICIÓN DE LA DISPERSIÓN O VARIACIÓN EN UNA DISTRIBUCIÓN DE PUNTIUACIONES

| | |
|--|-----|
| Introducción | 126 |
| El rango | 127 |
| Limitaciones del rango: situaciones en las que representa sólo grado de concordia o errores | 128 |
| La desviación estándar | 129 |
| Permutante proporcional y lineal sobre la desviación estándar | 130 |
| Método abreviado para calcular la desviación estándar | 135 |
| Limitaciones de la desviación estándar | 136 |
| La desviación estándar como σ e integral de la estadística binomial | 137 |
| ¿Por qué se llama desviación "estándar"? | 137 |
| Puntuaciones estandarizadas (puntuaciones Z) | 138 |
| La distribución normal | 140 |
| Uso del rango para estimar la desviación estándar | 143 |
| Una ilustración completa del cálculo de los estadísticos de dispersión | 144 |




| |
|--|
| <p>Uso de un formato designado para calcular la desviación estándar 144</p> <p>Uso de un formato de distribución de frecuencias para calcular la desviación estándar 145</p> |
| <p>Presencia de errores de redondeo 147</p> |
| <p>Interpretación de los resultados de la desviación estándar en los gráficos de la media 147</p> |

Introducción

Reportar un estadístico de tendencia central por sí mismo no es suficiente para comunicar la forma de una distribución de puntuaciones. Dos muestras con las mismas medidas pueden tener formas sumamente diferentes. La figura 5-1 presenta dos distribuciones de edades para una muestra de alumnos de escuela primaria (edad incluía de niños hasta sexto grado, 0-X-6) y para una clase de tercer grado de una segunda escuela. La edad media de los alumnos en ambas escuelas es de 8.5 años. En la escuela X-6, sin embargo, los niños tienen entre 5 y 12 años. En la clase de tercer grado de la otra escuela ninguno de los alumnos es menor de 7 o mayor de 10 años de edad. Aunque estas dos distribuciones de edades tienen la misma tendencia central, sus puntuaciones se dispersan de manera muy diferente, con una mayor dispersión de edades en la escuela X-6.

FIGURA 5-1
Comparación de la dispersión de edades de alumnos en dos escuelas con las mismas medidas



El rango

52

El tema de este capítulo es la dispersión, es decir, cómo se extienden las puntuaciones de una variable de *intencionalidad* de la menor a la mayor y la forma de la distribución entre ellas. (Como una ayuda para la imaginación, recuerde que Johnny Appleseed dispersó semillas de manzana.) Existe un número infinito de posibles formas de distribución para una variable con una media dada. Todas las puntuaciones podrían agruparse alrededor de la media con la clara forma de una curva de campana, pero la curva podría ser de diferentes tamaños, dependiendo del tamaño de la muestra. O las puntuaciones podrían estar fuertemente sesgadas hacia un lado. Además de esto una sola variable puede tener diferentes dispersiones de una población a otra. Por ejemplo, el ingreso familiar anual para residentes en Estados Unidos varía desde cero hasta decenas de millones de dólares; mientras el ingreso familiar de los pobres que viven en proyectos de asistencia social varía desde cero hasta unos cuantos miles de dólares.

Dispersión

Cómo se extienden las puntuaciones de una variable de *intencionalidad* desde la menor a la mayor y la forma de la distribución entre ellas.

Los estadísticos de dispersión describen cómo se extienden las puntuaciones de una variable de *intencionalidad* a través de su distribución. Los estadísticos de dispersión permiten descripciones precisas de la extensión de casos en cualquier punto de una distribución. Así, siempre, si el gobierno estatal decide aumentar los impuestos para los ricos, considerando estadísticas de dispersión podemos identificar el nivel de ingresos del 5 por ciento más rico de todas las familias del país. De manera similar, si un programa de asistencia social se planea para cubrir sólo 10 000 familias de la ciudad, podemos establecer qué nivel de ingresos familiar califica para recibir la asistencia. Estudiar la dispersión es como pasear hacia atrás y hacia adelante a lo largo del eje X de un histograma, y observar dónde se concentran los casos. ¿La mayoría de los casos se congrega en el extremo de la izquierda o hacia algún lado? ¿Cuántos casos caen entre cualesquiera dos puntos? ¿Qué valor de la variable marca el 10 por ciento superior de casos? Los dos estadísticos de dispersión más usados se tratan más adelante: el rango y la desviación estándar.

Estadísticos de dispersión

Estadísticos que describen cómo se extienden las puntuaciones de una variable de *intencionalidad* a través de su distribución.

El rango es una expresión de cómo las puntuaciones de una variable de *intencionalidad* se distribuyen: de la menor a la mayor —la distancia entre las puntuaciones mínimas y

La desviación estándar

Limitaciones del rango: situaciones en las que reportario solo puede conducir a errores

Puesto que el rango utiliza las puntuaciones más extremas de una distribución, un valor extremo influirá enormemente su cálculo. Esto sucederá por las siete edades indicadas arriba. Los 45 años hicieron que el rango pareciera estar extendido por encima de los 24 años. Reportar esto daría la impresión de que la muestra tiene un número considerable de sujetos de 30 y 40 años. Un reporte más exacto estipularía que con la excepción del estudiante de 45 años, las edades varían un rango de 7 años (26 - 20 + 1 = 7). Omitir el valor extremo e incluirlo como una excepción es una forma razonable de ajustar esta limitación del rango.

El rango también está limitado por su estrecho alcance informativo. No nos dice nada sobre la forma de la distribución entre las puntuaciones extremas. Por ejemplo, las dos distribuciones ilustradas en la figura 5-2 tienen el mismo rango, sugiriendo formas similares, pero, de hecho, sus formas son radicalmente diferentes. Por último, hay poco que uno pueda hacer matemáticamente con el rango. En suma, el rango tiene utilidad limitada, sobre todo cuando se ilustra solo.

La desviación estándar

La desviación estándar es otra medida sumaria de la dispersión o la variación de las puntuaciones en una distribución. Este estadístico de dispersión es muy útil.





Figura 5-2. Conservación de las distribuciones con formas diferentes que tienen el mismo rango.



Efecto de los miembros de la muestra sobre la variación de la distribución.

50

El rango

Máxima en una muestra. Se calcula como la diferencia entre las puntuaciones máximas y mínimas, más el valor de la unidad de redondeo. El valor de la unidad de redondeo (por ejemplo, 1 si las puntuaciones se redondean al número entero más cercano, 0.1 si las puntuaciones se redondean a la décima más cercana y así sucesivamente) se suma para considerar el límite real inferior de la puntuación más baja y el límite real superior de la puntuación más alta.

- Cálculo del rango de una variable X de intervalación**
1. Ordene las puntuaciones en la distribución de menor a mayor.
 2. Identifique las puntuaciones mínima y máxima.
 3. Identifique el valor de la unidad de redondeo (véase el apéndice A como referencia).
 4. Calcule el rango:

$$\text{Rango} = (\text{puntuación máxima} - \text{puntuación mínima}) + \text{valor de la unidad de redondeo}$$

El rango
Expresión de cómo las puntuaciones de una variable de intervalo, razón se distribuyen de menor a mayor.

Cálculenos el rango para un problema de ejemplo. Suponga que X = edad (redondeado al año más cercano) y tenemos la siguiente distribución de puntuaciones:

- 21, 25, 43, 16, 20, 21, 25

Empiece por ordenar las puntuaciones:

- 20, 21, 21, 23, 25, 25, 43

Identifique las puntuaciones mínima y máxima de 20 y 43, respectivamente, e identifique que la unidad de redondeo es 1.

Calcule el rango:

$$\text{Rango} = (\text{puntuación máxima} - \text{puntuación mínima}) + \text{valor de la unidad de redondeo} = (43 - 20) + 1 = 24 \text{ años}$$

Como resultado del redondeo, el individuo que realmente 20 podría tener 19.5 años, y el de 43 años, podría tener 43.5 años. El rango de 24 años es la distancia entre estos límites reales menor y mayor de las puntuaciones; es decir, 43.5 años - 19.5 años = 24 años.

A menudo resulta más instructivo reportar las puntuaciones mínima y máxima por sí mismas, señalando que estas edades varían desde 20 hasta 43. De esta manera indirectamente mostramos que en la muestra no hay miembros de 20 años ni mayores de 43 años de edad.

ente del rango. Se acostumbra en los extremos de la distribución, el rango se aproxima a la dispersión desde las "extremidades" o extremos de la distribución. Observar el rango es como mirar un juego de bilí que está desde el alto de las tablas, es la medida para ser comparada por las curvas en cada extremo. En consecuencia, la dispersión estándar se define como la proporción que resulta de dividir el rango de tipo intervalo se refieren a la longitud de la distribución en relación con la puntuación media. La media es un estadístico de tendencia central y como tal proporciona un punto de enfoque que se centra "dentro" de la distribución. Observar la dispersión e partir de la media con su dispersión estándar es como mirar desde el centro de la cancha; el centro se atiende así en la distancia desde el centro de la cancha hasta otros puntos en cualquier dirección. Como la media, la dispersión estándar es muy apropiada con variables de intervalo, razón y variables ordinales de tipo intervalo.

Desviación estándar
 Describe cómo las puntuaciones de una variable de intervalo/razón y ordinal de tipo intervalo se extienden a lo largo de la distribución, en relación con la puntuación media.

Pensamiento proporcional y fórmula sobre la desviación estándar
 La desviación estándar se calcula determinando qué tan lejos está cada puntuación de la media — que tan lejos se aleja de la media. En este sentido, la desviación estándar es un derivado o producto de la media, y las dos medidas siempre se relacionan. De hecho, la frase "la media y la desviación estándar" es una de las más empleadas por los estadísticos. La desviación estándar — como que media sumaria de todas las puntuaciones en una distribución — nos dice con qué amplitud se agrupan las puntuaciones alrededor de la media. Como brevemente lo analizaremos, la desviación estándar también se mide en conjunción con la curva normal.

Antes de calcular una desviación estándar analicemos la fórmula. La siguiente fórmula sirve para calcular directamente la desviación estándar:

Método directo para calcular la desviación estándar

$$s = \sqrt{\frac{\sum(X - \bar{X})^2}{n - 1}}$$

Donde:

- s = desviación estándar para la variable X de intervalo/razón
- \bar{X} = media de X
- n = tamaño de la muestra

Vale la pena aproximarnos paso a paso al cálculo de la desviación estándar. Esto clarifica el significado de la fórmula (con su Σ , cuadrados y símbolos de raíz cuadrada) y nos ayuda a apreciar que la desviación estándar es parte esencial de la curva normal.

Identifiquemos las especificaciones. Empezamos identificando la información dada. Especificaciones: X = una variable de intervalo/razón (el ordinal de tipo intervalo); n = tamaño de la muestra; y la distribución de puntuaciones es el bueno para X . Calcule la media. Calculamos la media porque la desviación estándar está definida para medir la dispersión alrededor de la media.

$$\bar{X} = \frac{\sum X}{n}$$

Calcule las puntuaciones de la desviación: pensamiento lineal. Luego determinamos qué tan lejos de la media cae la puntuación de cada sujeto. La diferencia entre una puntuación y su media se llama puntuación de desviación, es decir, número *ajuste* o *se desvía* de la media una puntuación individual.

$$X - \bar{X} = \text{puntuación de desviación para un valor de } X$$

Piense en una puntuación de desviación como una medida de distancia en el eje X . Qué nos dice la puntuación de desviación? Suponga que X es la variable peso, y el peso medio para una muestra de jugadores de voleibol de la Universidad de Hawthorn es de 136 libras. Los jugadores estrella, Sandra "Olivadora" de altura, Carson, pese 173 libras; ese es su puntuación en bruto o "puntuación X ". Su puntuación de desviación es más 35 libras:

$$\text{Puntuación de desviación} = X - \bar{X} = 173 - 138 = 35 \text{ libras}$$

La puntuación de desviación nos dice dos cuestiones sobre una puntuación en la distribución: 1) la magnitud de la distancia desde la puntuación X hacia la media, y 2) la dirección de la puntuación X ; ya sea que está abajo o arriba de la media. Cuando una puntuación X es mayor que la media, la puntuación de desviación X queda a la derecha en una curva de distribución. Cuando una puntuación X es menor que la media, la puntuación de desviación X queda a la izquierda de la media. La puntuación de desviación de Sandra es +35 libras nos indica que ella está 35 libras más allá del peso medio del equipo.

Puntuación de desvío

$$\text{Cada uno arriba o "se desvía" de la media es la puntuación individual}$$

144

La puntuación de desviación es el cálculo matemático central al determinar la desviación estándar. Como una medida sumaria para la muestra entera, la desviación estándar es una suma y promedio del cuadrado de estas puntuaciones de desviación, como en los siguientes pasos.

Suma las puntuaciones de desviación. El siguiente paso para calcular la desviación estándar consiste en sumar las puntuaciones de desviación. Tal suma siempre será igual a cero (dentro del error de redondeo).

$$\sum(X - \bar{X}) = 0 = \text{suma de las puntuaciones de desviación}$$

La suma de puntuaciones de desviación constituye una verificación respecto de la exactitud de los cálculos, porque la suma de puntuaciones de desviación siempre será igual a cero (con cierto error de redondeo). En el capítulo 4 estudiamos cómo la media es un punto de balance en la distribución. Lo que la media hace es balancear las desviaciones, para que se cancelen entre sí y resulten en una suma de puntuaciones de desviación igual a cero. De hecho, otra definición matemática de la media es *ese el punto en una distribución donde las puntuaciones de desviación suman cero*.

Breve al cuadrado las puntuaciones de desviación y suma los cuadrados. La dispersión de una variable a menudo se compara para dos o más muestras. El hecho de sumar las puntuaciones de desviación no detectará una diferencia en la dispersión entre dos muestras, porque la suma para ambas será cero. Esto potencialmente nos deja en un callejón sin salida. Si las puntuaciones de una muestra se dispersan ampliamente y las de la otra lo hacen de manera estrecha, ¿qué beneficio implica informar que ambas tienen una suma de puntuaciones de desviación de cero? Ninguno! Por consiguiente, al comparar dos muestras, debemos encontrar una manera de sumar las puntuaciones de desviación para que la suma sea más grande para una muestra con una dispersión mayor. La solución más útil consiste en elevar al cuadrado cada puntuación de desviación y después sumar los cuadrados. Al elevar al cuadrado se eliminan los signos negativos en las puntuaciones de desviación. La suma de las puntuaciones de desviación al cuadrado es la variación (a menudo se denomina suma de cuadrados), un estadístico que resume las desviaciones para la muestra entera:

$$\sum(X - \bar{X})^2 = \text{la variación (o suma de cuadrados)}$$

La variación o la suma de cuadrados

Es la suma de las puntuaciones de desviación al cuadrado; un estadístico que resume las desviaciones para la muestra entera.

Divide la suma de cuadrados entre $n - 1$ para ajustar el tamaño y el error de la muestra para el tamaño muestral. La suma de cuadrados, o variación, constituye una buena medida de la dispersión de una distribución; pero este estadístico presenta dos problemas. Primero, surge el que estamos comparando las distribuciones de dos muestras de tamaños diferentes. Por ejemplo, podemos comparar las dis-

tribuciones de los promedios para muestras de tamaños de la universidad local ($n = 88$) y de la universidad estatal ($n = 104$). Como con cualquier otro estadístico, los cuadrados para cada muestra, podría suceder que obtuviéramos una suma de cuadrados alta para la universidad estatal, simplemente porque sumamos más números. En otros palabras, solo 88... Cada puntuación X suma significativamente más a la suma en lugar de bajar, todo lo demás es igual, cuando más observaciones hay, mayor será la suma de cuadrados. Para realizar una comparación justa de las puntuaciones de puntuación de puntuación, necesitamos ajustar los cuadrados para tener en cuenta la división de cada uno entre su tamaño muestral. De esta forma ajustamos la suma de cuadrados en proporción al tamaño de la muestra.

Una segunda consideración respecto al tamaño de la muestra es que cuanto al error de muestra, cuanto mayor sea la muestra, menor será el error de muestra. Los estadísticos han demostrado que si restamos $1/n$ a este pequeño ajuste, produce un estadístico de la muestra que estima con mayor precisión el parámetro de la población. Simplemente, narrando el delirio de las muestras, restamos un ajuste para el error de muestra. (Considere que con muestras grandes, este ajuste tendrá poco efecto en el cálculo, mientras que con muestras pequeñas, tendrá un gran efecto.)

En resumen, dividimos la variación (suma de cuadrados) entre $n - 1$ para considerar tanto los efectos del tamaño de la muestra en la suma como el error de muestra. El resultado se llama *varianza*, y su símbolo es s^2 :

$$s^2 = \frac{\sum(X - \bar{X})^2}{n - 1} = \text{varianza de una muestra}$$

La varianza es la medida promedio de las puntuaciones en una distribución. Para evitar confundir la varianza y variación, que a menudo se usan en "varianza" y "variación" en su denominador. Finalmente, debemos hacer notar que si la desviación estándar se calcula para las puntuaciones de una población entera, el error de muestra no constituye un problema. Por consiguiente, no necesitamos restar $1/n$ para obtener la variación de una población, lo que se simbolizará como σ^2 .

Varianza

Medida promedio de las puntuaciones en una distribución; es decir, la media de la suma de cuadrados.

Seque la raíz cuadrada de la varianza para obtener la desviación estándar. Para producir una buena medida de dispersión se requiere un último paso. La varianza es absolutamente aceptable para cálculos, pero no se puede interpretar directamente porque las unidades de medida están elevadas al cuadrado. Así, podemos interpretar la varianza de pesos para el equipo de fútbol de la universidad local y encontraríamos que es de 137.45 libras cuadradas. No obstante, ¿qué es una "libra cuadrada"? Es una libra de veces una libra; pero ¿qué sabe lo que realmente significa, excepto quizás un matemático? Necesitamos una unidad de medida directamente interpretable —libras en lugar de libras al cuadrado. Para "desenredar" a libra, simplemente

mo la raíz cuadrada de la varianza. La raíz cuadrada de una unidad de medida al cuadrado es la unidad de medida en sí. El resultado es la desviación estándar.

$$s_x = \sqrt{\frac{\sum(X - \bar{X})^2}{n-1}} = \sqrt{37.3}$$

En el caso del peso del equipo de fútbol la desviación estándar sería 37.30 libras.

$$s_x = \sqrt{\frac{\sum(X - \bar{X})^2}{n-1}} = \sqrt{139.45} = 37.30 \text{ libras}$$

Los pasos previos en este caso involucran un cálculo directo de la desviación estándar. Los elementos de la serie de datos —las puntuaciones de desviación, la suma de cuadrados y la raíz cuadrada— son los puntajes de desviación. Estos elementos aparecen por sí mismos en muchas fórmulas estadísticas (véase, por ejemplo, el capítulo 11). Los pasos para calcular directamente la desviación estándar se resumen en la tabla 5-1, que usted encontrará muy útil para los capítulos posteriores.

Tabla 5-1. Computación de la desviación estándar en cálculo directo

| Pasos para calcular la desviación estándar | | La raíz cuadrada de | |
|--|--|---|--|
| 1. Identificar las puntuaciones | | 1. X debe ser una variable de intervalo/razón (la medida de peso, inventario) | |
| 2. Calcular la media | $\bar{X} = \frac{\sum X}{n}$ | 2. Puntaje a que la desviación estándar está basado en desviaciones de la media | |
| 3. Calcular las puntuaciones de desviación | $X - \bar{X}$ | 3. Para encontrar la distancia de cada puntuación hacia la media | |
| 4. Sumar las puntuaciones de desviación | $\sum(X - \bar{X})$ | 4. Asignar el signo | |
| 5. Hacer el cuadrado de las puntuaciones de desviación y sumarlo para obtener la variación o suma de cuadrados | $\sum(X - \bar{X})^2$ | 5. Las puntuaciones de desviación se elevan al cuadrado para eliminar los signos negativos y obtener una suma cuadrada de cero | |
| 6. Calcular la varianza | $\frac{\sum(X - \bar{X})^2}{n-1}$ | 6. Dividir la suma de cuadrados entre $n-1$ para ajustar por el tamaño de muestra y el grado de libertad | |
| 7. Calcular la desviación estándar | $s_x = \sqrt{\frac{\sum(X - \bar{X})^2}{n-1}}$ | 7. Sacar la raíz cuadrada de la varianza para obtener unidades de medida. Determinar si las puntuaciones originales en lugar de unidades de variación | |

Tabla 5-2. Formato desajustado para calcular la desviación estándar usando los métodos directo y abreviado: peso de los jugadores de fútbol de la universidad local ($n = 12$)

| Puntuaciones | | Cálculos | | |
|--------------|------------------------|-------------------------|--|--------------------------------------|
| (1) | (2) | (3) | (4) | (5) |
| Jugador | X | $X - \bar{X}$ | $(X - \bar{X})^2$ | X |
| 1 | 165 | -73 | 5329 | 57115 |
| 2 | 200 | -38 | 1444 | 40000 |
| 3 | 218 | -20 | 400 | 48456 |
| 4 | 217 | -21 | 441 | 47089 |
| 5 | 226 | -12 | 144 | 51078 |
| 6 | 234 | -4 | 16 | 55696 |
| 7 | 259 | 11 | 121 | 57121 |
| 8 | 276 | 28 | 784 | 59328 |
| 9 | 281 | 33 | 1089 | 63121 |
| 10 | 268 | 20 | 400 | 68124 |
| 11 | 283 | 25 | 625 | 71524 |
| 12 | 201 | -57 | 3249 | 80359 |
| $n = 12$ | $\sum X = 2856$ libras | $\sum(X - \bar{X}) = 0$ | $\sum(X - \bar{X})^2 = 15508$ libras cuadradas | $\sum X^2 = 685041$ libras cuadradas |

Resulta una buena práctica preparar una tabla desajustada para estos cálculos. La tabla 5-2 presenta una tabla desajustada para determinar la desviación estándar de los pesos de 12 de los jugadores en el equipo de fútbol local. (La columna 5 de la tabla se completa con un método de cálculo abreviado que se describe brevemente.) Para calcular las puntuaciones de desviación, $X - \bar{X}$, calculamos la media y le restamos cada puntuación para obtener la tercera columna de la tabla desajustada:

$$\bar{X} = \frac{\sum X}{n} = \frac{2856}{12} = 238 \text{ libras}$$

Entonces elevamos al cuadrado las puntuaciones de desviación en la columna 3 para obtener la columna 4. La suma en la columna 4 de la tabla 5-2 y el tamaño de la muestra n son todo lo que necesitamos para calcular la desviación estándar:

$$s_x = \sqrt{\frac{\sum(X - \bar{X})^2}{n-1}} = \sqrt{\frac{15508}{11}} = \sqrt{1394.5} = 37.30 \text{ libras}$$

Método abreviado para calcular la desviación estándar
 Nuestro propósito para realizar el cálculo directo de la desviación estándar consiste en desarrollar un sentido de proporción acerca de cómo mide las desviaciones con respecto a la media. Sin embargo, si desea hacer una tarea difícil, calcular direc-

B/C

ramente la desviación estándar resultaría embarazoso y propenso al error. Resulta calcular la media y, después, efectuar muchas restas también propensas al error, algo que es especialmente fastidioso con números decimales. Por fortuna, existe un método abreviado de cálculo al cual se llega sustituyendo $\sum(X - \bar{X})/n$ por la media de X y extendiendo la ecuación de la fórmula diversa.

$$s^2 = \frac{\sum(X - \bar{X})^2}{n - 1} = \frac{\sum(X^2 - 2X\bar{X} + \bar{X}^2)}{n - 1} = \frac{\sum X^2 - 2\bar{X}\sum X + n\bar{X}^2}{n - 1}$$

Método abreviado para calcular la desviación estándar

$$s^2 = \frac{\sum X^2 - \frac{(\sum X)^2}{n}}{n - 1}$$

donde

s^2 = desviación estándar para la variable de intervalo/razón, X
 n = tamaño de la muestra

Esta fórmula abreviada no requiere calcular la media ni las puntuaciones de desviación. En la tabla 5-2, simplemente elevamos al cuadrado cada puntuación en bruto en la columna 2, para obtener la columna 3. Entonces las sumas de las columnas 2 y 3 se insertan en la fórmula abreviada:

$$s^2 = \frac{\sum X^2 - \frac{(\sum X)^2}{n}}{n - 1} = \frac{695,034 - \frac{(2,856)^2}{11}}{11} = 57.22 \text{ horas}$$

Una nota premenuda. Tenga cuidado en distinguir entre $\sum(X^2)$, la misma suma (de la columna 2) que sirve para calcular la media, y $(\sum X)^2$ de la columna 3. Con el propósito de evitar ambigüedades, calcule la desviación estándar mediante ambos métodos, resulta una buena manera de detectar los errores de cálculo. Si los dos resultados no son los mismos con un pequeño margen de error de redondeo, verifique todos sus cálculos una vez más.

Limitaciones de la desviación estándar

Ya que la desviación estándar se calcula a partir de la media, cualquier que ésta, se vea por los valores extremos. Estos grandes puntuaciones son grandes desviaciones. Cuando se elevan al cuadrado, estas grandes desviaciones, ya sean positivas o negativas, producen una gran puntuación positiva también. Así, la desviación estándar puede ser muy confusa cuando se repasa para una distribución sesgada, en la que pocas puntuaciones se extienden en una dirección. En su experiencia del

efecto de las puntuaciones extremas como en la media como en la desviación estándar, complete la tabla designada de la tabla 5-2; pero agregue los dos casos siguientes para obtener una nueva muestra con $n = 4$: el jugador 13 que pesa 115 libras, y el jugador 14 que pesa 135 libras. A continuación compare las respuestas de las muestras original y nueva.

La desviación estándar como parte integral de la estadística inferencial

Las características de la media y de la desviación estándar, las hacen muy útiles para abarcar un sentido de proporción respecto de las variaciones individuales que se estudian. La desviación estándar y las puntuaciones de desviación, a partir de las cuales se calculan, también son esenciales para examinar las relaciones entre dos variables. El enfoque de la estadística inferencial, consiste en desarrollar una comprensión de por qué las puntuaciones individuales de una variable dependiente se desvían de su media.

Suponga, por ejemplo, que estamos estudiando el abuso en el consumo de alcohol. Para una muestra de bebedores adultos, encontramos que la media del consumo de bebidas alcohólicas es de 4.3 galones por año. Gary consumió 7.3 galones el último año, 3 galones arriba de la media. Sam consumió sólo 1 galón, 3.3 galones abajo de la media. ¿Qué sucede con estas desviaciones alta y baja? Quizá podamos hipotetizar acerca de algunas variables predictoras (independientes) que creamos que están relacionadas con esta variable dependiente. Por ejemplo, la hipótesis del consumo a la hora de la comida podría explicar, en parte, la variación de desviación positiva de Gary; los bebedores de familias que consumen vino con sus alimentos tienen un consumo de alcohol más alto. Existe también la hipótesis del bebedor social, la cual podría explicar, en parte, la puntuación de desviación negativa de Sam; los bebedores que sólo consumen alcohol cuando se sirve en convivios sociales tienen un consumo de alcohol medio más bajo.

Para una muestra completa, nuestro interés radica en explicar la variación — la suma de puntuaciones de desviación al cuadrado—. Las puntuaciones de desviación, la variación y la desviación estándar simplemente son medidas de diferencias en las puntuaciones para una variable entre los sujetos de una población. Es más alta la variación media de consumo de alcohol anual para las personas de ciertas regiones, entre diferentes edades o grupos religiosos o entre sexos? Las respuestas a estas preguntas, dependen de las propiedades matemáticas de la media, la desviación estándar, y la curva normal.

¿Por qué se llama desviación "estándar"?

La desviación estándar recibe su nombre de hecho de que proporciona una medida de medida común (un estándar) para comparar variaciones con unidades de medida diferentes muy diferentes. Por ejemplo, imagine que Mary Smith y Jason Jones estudian para una clase con base en su desempeño en las pruebas de admisión a la universidad. Mary obtuvo la prueba a nivel de la universidad (PAU) y obtuvo 26 puntos PAU. Jason hizo lo propio con la prueba de admisión estándar (EAS) y obtuvo 90 puntos EAS. Estos dos resultados de las pruebas tienen unidades de medida

57

Muy diferentes los puntos de la prueba PAU varían de cinco a 36 y los de la prueba PAS, de 200 a 1 600. Las puntuaciones en bruto para las dos pruebas no pueden compararse directamente. Usando las medidas y las desviaciones estándar para ambas pruebas, sin embargo, podemos crear una escala para compararnos. Con los siguientes estadísticos, encontramos que, en comparación con otros estudiantes que contestan estas pruebas Mary tuvo la puntuación mayor:

$$X = \text{puntuación de la prueba PAU} \quad \bar{X} = 22 \text{ puntos PAU} \quad s_x = 2 \text{ puntos PAU}$$

$$Y = \text{puntuación de la prueba PAS} \quad \bar{Y} = 1 000 \text{ puntos PAS} \quad s_y = 100 \text{ puntos PAS}$$

La puntuación PAU de 26 que obtuvo Mary tiene una desviación estándar de 2 arriba de la media de aquellas que tomaron la prueba PAU; es decir, su puntuación está 4 puntos PAU — 2 veces la desviación estándar — sobre el promedio de 22. La puntuación de Jason es de 2 desviaciones estándar abajo de la media de aquellos que contestaron la prueba PAS; es decir, su puntuación está 100 puntos PAS — 1 desviación estándar — debajo del promedio de 1 000. Sin lugar a dudas podemos comparar la hora a Mary. Utilizando las desviaciones estándar como unidades de medida en lugar de "puntos de prueba PAU" y de "puntos de prueba PAS", tenemos una vía de medición común o estándar para ambas variables — de ahí el nombre de "variación estándar". ¿Quién le dijo que no podía comparar manzanas con naranjas?

Puntuaciones y variaciones estándar (conversiones Z)

El ejemplo anterior ilustra el hecho de que la puntuación de un sujeto de la universidad en cualquier variable de interés/franja puede expresarse de diversos maneras. Primero, lo expresamos en sus unidades de medida observadas, originales, como una puntuación en bruto. Por ejemplo, la puntuación en bruto X de Mary es 26 puntos PAU. Segundo, lo expresamos como una desviación de la media (es decir, la puntuación de desviación $X - \bar{X}$). La puntuación de desviación de Mary es -4 y significa que ella obtuvo 4 puntos PAU arriba de la media de aquellos que tomaron el PAU. Tercero, expresamos su puntuación como un número de desviaciones estándar al PAU. Tercero, expresamos su puntuación como un número de desviaciones estándar (o puntuación Z) que para la variable X se elige como sigue:

Forma de puntuación para una variable Y y su desviación

$$Z = \frac{X - \bar{X}}{s_x}$$

donde

- Z = puntuación estandarizada para un valor de X
- \bar{X} = número de desviaciones estándar que una puntuación en bruto (puntuación X) se sitúa de la media
- s_x = una variable de desviación/medida
- X = la puntuación de X
- s_x = la desviación estándar de X

Si establecemos que X = puntuación PAU con $\bar{X} = 22$ puntos PAU y $s_x = 2$ puntos PAU, la puntuación Z de Mary es

$$Z_x = \frac{X - \bar{X}}{s_x} = \frac{26 - 22}{2} = \frac{4}{2} = 2.00 \text{ DE}$$

donde DE quiere decir "desviaciones estándar". Una puntuación Z es la distancia de una puntuación X hasta la media (es decir, su puntuación de desviación) dividida entre la desviación estándar de las desviaciones.

Una clave para tener claras estas tres maneras de expresar la puntuación consiste en enfocarse en las unidades de medida. Las puntuaciones en bruto y las puntuaciones de desviación para una variable se presentan en la unidad de medida original observada que por supuesto, es debida por una variable. Por ejemplo, la unidad de medida observada para edad es años, para peso, libras o kilogramos; para altura, pulgadas o centímetros; y así sucesivamente. Pero no importa de qué unidad de medida de una variable se trate, sus puntuaciones Z se miden en DE. La tabla 5-3 resume estas distinciones.

Aquí aparecen algunos ejemplos de una muestra aleatoria de mujeres estudiantes en la universidad local.

| Caso | X (peso) | \bar{X} (puntuación de desviación) | s_x (puntuación estandarizada) |
|----------------|------------|--------------------------------------|----------------------------------|
| Cheryl Jones | 110 libras | -10 libras | -1 DE |
| Jennifer Smith | 125 libras | 5 libras | 5 DE |
| Terri Bennett | 107 libras | -13 libras | -1.5 DE |

| Caso | Y (altura) | \bar{Y} (puntuación de desviación) | s_y (puntuación estandarizada) |
|----------------|-------------|--------------------------------------|----------------------------------|
| Cheryl Jones | 64 pulgadas | -1 pulgadas | -3.5 DE |
| Jennifer Smith | 65 pulgadas | 0 pulgadas | 0 DE |
| Terri Bennett | 68 pulgadas | 3 pulgadas | 1 DE |

Tabla 5-3 Las diferentes formas en que se pueden presentar las puntuaciones de una variable

| Forma de puntuación para una variable Y y su desviación | Unidad de medida de la variable | Ejemplo X = altura |
|---|---|--------------------|
| Puntuación en bruto (puntuación X) | La unidad de medida de la variable | Pulgadas |
| Puntuación de desviación $X - \bar{X}$ | La unidad de medida de la variable | Pulgadas |
| Puntuación estandarizada (Z) o "puntuación Z" | Desviaciones estándar de la variable (DE) | DE |

58

Tiene presente que tanto las puntuaciones de desviación como las puntuaciones Z son medidas de la distancia desde la puntuación en bruto de una variable hasta su media. La puntuación de desviación se obtiene restando la media de la puntuación en bruto (es decir, $X - \bar{X}$). Al dividir esta puntuación de desviación entre la desviación estándar, obtenemos esta puntuación de desviación en las partes y miltiplos de las desviaciones estándar desde la media. Recuerde que después de calcular la media, calcular las puntuaciones de desviación es lo siguiente que hacemos cuando calculamos la desviación estándar. La esencia de la desviación estándar está en ver una puntuación en bruto individual como una desviación desde la media.

Para obtener un buen sentido de proporción sobre las fórmulas para las puntuaciones de desviación y las puntuaciones Z , examinemos las relaciones entre los tamaños de las puntuaciones Z , examinemos las relaciones entre las puntuaciones Z . Primero, cuanto más lejos de la media está una puntuación X , mayores serán su puntuación de desviación y su puntuación Z . Es más, el signo de cualquier puntuación de desviación y puntuación Z indica la dirección de una desviación de la media (la dirección negativa). El signo "-" (signo menos) indica que una puntuación en bruto está debajo de la media; el signo "+" (signo más), que está implícito, no escrito, indica que está encima de la media. En los ejemplos anteriores, Cheryl y Jerry están debajo del promedio en peso, y Jerry está encima del promedio en altura. De hecho, a partir de esas puntuaciones Z podemos decir que Jerry es una persona alta, delgada — más de 1 DE debajo en peso, pero 1 DE arriba en altura —, Jennifer tiene altura media; así, su puntuación de desviación y su puntuación Z para Y son cero; ella no se desvía de la altura media.

Puesto que usaremos puntuaciones Z o medias similares de desviación en cada capítulo en el resto del texto, es prudente practicar cómo calcular puntuaciones de desviación y puntuaciones Z , así como estudiar las direcciones (signos) de esas puntuaciones. Se recomienda una doble verificación. Si una puntuación en bruto queda debajo de la media, su desviación y sus puntuaciones Z son negativas. También tenga presente que las puntuaciones Z son simplemente otra manera de expresar puntuaciones en bruto. Cada puntuación en bruto tiene una puntuación Z correspondiente, y viceversa.

La distribución normal

Además de proporcionar un estándar de comparación entre variables y muestras diferentes, bajo las condiciones apropiadas la media y la desviación estándar ofrecen una riqueza de información. Es así el caso cuando una variable tiene una distribución de puntuaciones que es normal — formada como la curva de distribución normal—. Como lo definimos en el capítulo 4, una distribución normal es simétrica, con su media, mediana y modo iguales entre sí y localizadas en el centro de la curva. Sin embargo, la simetría o balance en la curva representa la imagen completa. La curva normal también tiene una forma de campana inconfundible, que no es muy plana ni demasiado puntiaguda. Muchas variables se distribuyen

normalmente (como altura, peso e inteligencia). Sin tener en cuenta qué variable se examina, si está normalmente distribuida, posee las propiedades de una curva normal.

Lo que vuelve a la desviación estándar una herramienta estadística tan valiosa es que constituye una parte invariante de la curva normal. Cuando usted sigue la curva desde su centro (es decir, su pico) en cualquier dirección, la curva siempre se forma y se agrupa al eje de las X . Desde el pico, al punto en el cual la curva empieza a cambiar hacia afuera es 1 desviación estándar de la media. Este punto es llamado punto de inflexión y se destaca en la figura 5-3. Esto indica que la media y la desviación estándar son aspectos invariantes de un fenómeno natural: la tendencia hacia una distribución normal, en forma de campana para muchos eventos naturales.

Comprender el fenómeno de normalidad es un aspecto importante de la línea gráfica estadística. Muchos fenómenos que ocurren naturalmente tienen distribuciones de frecuencias que tienen la forma de una curva normal. La curva normal ilustra el hecho de que cuando nos damos cuenta de la media, esperamos encontrar cada vez menos casos. Para muchas variables, existe un promedio alrededor del cual casi la mayoría de las puntuaciones, y cuando nos alejamos de este promedio, las frecuencias del caso disminuyen. Por ejemplo, la altura física se distribuye normalmente; la mayoría de las personas está cerca del promedio, con unas cuantas personas muy altas y muy bajas.


Uno de los rasgos más sobresalientes del fenómeno de normalidad que ocurre naturalmente es que ofrece predicciones precisas sobre cuantas puntuaciones de una población caerán dentro de cualquier rango de puntuaciones. Como se ilustra en la figura 5-3, para cualquier variable normalmente distribuida:

1. Cincuenta por ciento de las puntuaciones caerán encima de la media, y 50 por ciento debajo. Esto se debe al hecho de que la mediana es igual a la media.
2. Virtualmente todas las puntuaciones caerán dentro de 3 desviaciones estándar a partir de la media en ambas direcciones. Esto es una distancia de 3 puntuaciones Z debajo hasta 3 puntuaciones Z encima de la media, una amplitud total de 6 desviaciones estándar. La cantidad precisa es 99.7 por ciento. El restante 0.3 por ciento de casos (es decir, 3 casos de cada 1,000) caerán fuera de 3 desviaciones estándar y, técnicamente, la curva se extiende hacia el infinito en ambas direcciones. (Prácticamente hablando, las puntuaciones para algunas variables, como el peso corporal, tienen límites físicos.)
3. Cerca del 95 por ciento de las puntuaciones de una variable normalmente distribuida caerán dentro de una distancia de 2 desviaciones estándar en ambas direcciones de la media. Esto es más o menos 2 puntuaciones Z de la media.
4. Aproximadamente 68 por ciento de las puntuaciones de una variable normalmente distribuida caerán dentro de una distancia de 1 desviación estándar (más o menos 1 punto Z) en ambas direcciones de la media.

Tenga presente que la distribución normal tiene características muy prácticas. Si una variable se distribuye en esta peculiar forma de campana, podemos utilizar las estadísticas de la muestra y lo que sabemos respecto de la curva normal para estimar cuantas puntuaciones se encuentran en un punto o dentro de cierto rango.

50


FIGURA 5-3
La relación de la
distribución estándar
con la curva normal



Para dibujar la unidad de la curva normal seguimos el ejemplo anterior. Una muestra de muchos estudiantes de la universidad local, donde $X =$ peso, el peso medio es de 120 libras y $\sigma = 10$ libras. Primero, necesitamos asegurarnos de que la distribución de puntuaciones es de hecho normal; es decir, que tiene forma de campana. Esto podría hacerse produciendo un histograma de puntuaciones de una muestra (no mostrada). Si este gráfico se aproximadamente tiene forma de campana, supongamos que esa variable no sólo está normalmente distribuida en la muestra, sino también en la población. Nos referimos a este hecho como "asumiendo la normalidad". En forma de un histograma de la muestra puede ser ligeramente fuera de lo normal, como resultado del error muestral. Como se grafica en la figura 5-4, asumimos la normalidad, podemos hacer las siguientes estimaciones de los pesos de la población de menores estudiantes en la universidad local:

1. La mitad de esos estudiantes pesa arriba de 120 libras.
2. Cerca de 68 por ciento de los menores estudiantes de la universidad local pesan entre 110 y 130 libras.


$X =$ peso $\mu = 120$ libras $\sigma = 10$ libras



3. Aproximadamente 65 por ciento de los menores estudiantes de la universidad local pesan entre 100 y 140 libras.
4. Muy pocas pesan menos de 90 libras o más de 150 libras.

Recuerde, una puntuación Z simplemente es una forma de expresar una puntuación en bruto (es decir, la puntuación observada en una observación individual). Si Susannah pesa 110 libras, ella está 10 libras por debajo del promedio y tiene una puntuación Z de -1.00 DE.

66



Notamos que apenas el 66 por ciento de los casos en una población normalmente distribuida tienen puntuaciones X dentro de una distancia de 1 desviación estándar en ambos lados de la media (es decir, entre una puntuación Z de más y menos 1). Por ejemplo, suponga que tenemos la siguiente población, donde X = estatura para una muestra de hombres en un club deportivo:

$$\bar{X} = 69 \text{ pulgadas} \quad s_x = 3 \text{ pulgadas} \quad \text{La distribución es normal}$$

Puesto que esta distribución es normal, tracemos la curva normal. Para obtener un sentido de proporción respecto de cuántos hombres son 1.5 o altos. Nuestra conclusión bajo de la curva normal nos dice que casi 66 por ciento están entre 66 y 72 pulgadas, como se indica en la curva de la figura de arriba. Es más, ya que la media se localiza en la media, sabemos que la mitad de los hombres están debajo de las 69 pulgadas (cinco pies, nueve pulgadas) y la otra mitad está arriba. Y como casi el 66 por ciento de una población normalmente distribuida cae dentro de tres puntuaciones Z en ambos lados de la media, muy pocos son más bajos que 57 pulgadas o más altos que 75 pulgadas.

Así

$$P(\text{de } X = 66 \text{ a } X = 72) = \text{aproximadamente } 66\%$$

De hecho, con la ayuda de una tabla estadística, podemos calcular puntuaciones Z y usarlas para determinar cualquier área bajo la curva. Este procedimiento se llama partición de áreas bajo la curva normal, y en breve haremos algunas pautas.

Como resulta, las áreas bajo la curva normal representan probabilidades de ocurrencia. Observe que utilizamos el símbolo μ para representar proporciones y probabilidades. Las probabilidades son proporciones del número de veces que se da un éxito de todas las posibles ocurrencias. Conocer la proporción de éxito de la población en un caso nos da la probabilidad de éxito por un solo suceso. En otras palabras, un área específica bajo la curva normal proporciona la probabilidad de ocurrencia de cualquier puntuación sola que sea entre cualesquiera dos valores.

Para ilustrar esta relación, suponga que estamos jugando al béisbol en el club deportivo. Para e intentaríamos jugar un partido de béisbol llamado "adivina la estatura". Las reglas del juego son tales que cuando cinco jugadores acertaron desde la izquierda, suponemos su estatura y después se le programamos cuando se acerta. Si estamos dentro de 3 pulgadas de la estatura correcta, ganamos.

Uso de la curva normal como una distribución de probabilidad

Pensamiento proporcional respecto de un grupo de casos y casos únicos

Como observamos en el capítulo 5, la desviación estándar sirve para examinar la forma en que las puntuaciones se dispersan en una distribución, y para comparar la dispersión de dos o más muestras. Sin embargo, podemos lograr mucho más con la desviación estándar. Con una sola variable de intervalo/razón que tenemos razón para creer que está normalmente distribuida en su población, podemos calcular puntuaciones estandarizadas (puntuaciones Z) y usarlas para determinar la proporción (y) de puntuaciones de una población que caen entre cualesquiera dos puntuaciones en la distribución. Puesto que la curva normal tiene una forma inconfundible, podemos identificar y medir áreas porque éstas representan una proporción de casos.

Recuerde del capítulo 5 que una puntuación Z nos dice cuántas desviaciones estándar está alejada una puntuación bruta (o puntuación X) de la media:

$$Z_x = \frac{X - \bar{X}}{s_x} = \text{número de desviaciones estándar (DE) desde la media}$$

61

