


【分散 (variance) と標準偏差 (SD: standard deviation) のわかりやすい説明】

- 下の2つの分布はどちらも人数が10人 (N=10), 平均値と中央値 (Md) はいずれも5である。しかし, 広がり具合が違い, Bの方がAよりも広がっている。この広がり (散らばり) の違いをどのように表現 (数量化) したら良いだろうか?



(1)そこで, 一人一人が平均 (=5) からどの位離れているかを求めてみる。

4-5=-1	3-5=-2
4-5=-1	3-5=-2
4-5=-1	4-5=-1
5-5= 0	4-5=-1
5-5= 0	5-5= 0
5-5= 0	5-5= 0
5-5= 0	6-5= 1
6-5= 1	6-5= 1
6-5= 1	7-5= 2
+) 6-5= 1	+) 7-5= 2
0	0

それぞれの全体的大きさを比較するために合計すると0になってしまう (平均値の定義から当然そうなる)。

(2)そこで, 各値を2乗してから合計してみると

$(4-5)^2 = (-1)^2$	$(3-5)^2 = (-2)^2$
$(4-5)^2 = (-1)^2$	$(3-5)^2 = (-2)^2$
...	...
...	...
+) $(6-5)^2 = 1^2$	+) $(7-5)^2 = 2^2$
6	20

となり, (B)の方が大きくなる。しかし, この場合はdata数が同じ (10個) だから比較できるが, data数が異なると大きさの比較ができない。そこで, これらの値をdata数で割る (この場合, data数-1の値で割ったものを使う: 不偏分散)。

$$6 / (10-1) = 2/3 \qquad 20 / (10-1) = 20/9$$

これらの値を分散 (variance) という。そして, この値の平方根を標準偏差 (SD: standard deviation) という。

●チェビシェフの不等式

標準偏差 (SD) の値には, 次のような性質がある (x_{mean} は平均, s_x はSDを表す)。

$$P \{ |x_i - x_{mean}| \leq k \cdot s_x \} > 1 - 1/k^2$$

具体的には, $k = 2$ とすると, 平均から $\pm 2 s_x$ の中に, 全dataの75%以上が含まれることになる。この性質は分布の形とは関係せずに成立する。