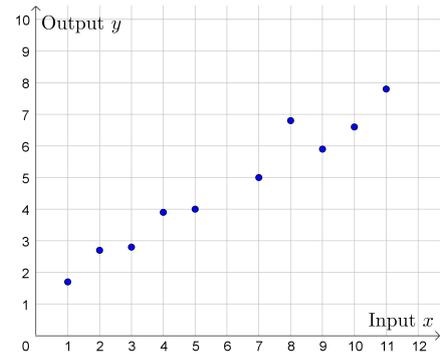


Modellierung  **MmF**

Wir führen eine Messreihe durch.
Abhängig vom Input x erhalten wir einen Output y als Messwert.

Die Messergebnisse sind rechts dargestellt.

Mit welchem Output y rechnest du ungefähr,
wenn der Input $x = 6$ ist?



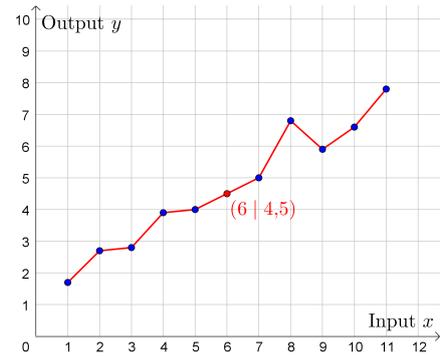
Stückweise lineare Interpolation  **MmF**

Rechts arbeiten wir mit **stückweise linearer Interpolation**.

Wir verbinden dabei von links nach rechts benachbarte Messpunkte durch eine Strecke.

So erhalten wir den Graphen einer stückweise linearen Funktion.

Beim Input $x = 6$ sagen wir mit stückweise linearer Interpolation den Output $y = 4,5$ voraus.



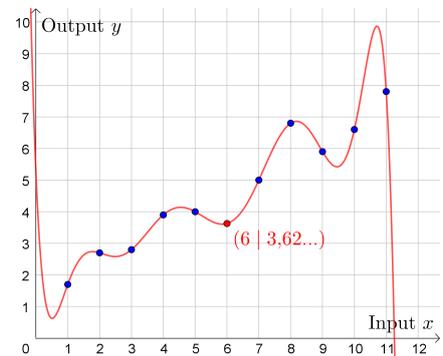
Overfitting  **MmF**

Rechts arbeiten wir mit Polynominterpolation.

Wir legen also eine Polynomfunktion *exakt* durch die Messpunkte.

Beim Input $x = 6$ sagen wir mit Polynominterpolation den Output $y = 3,62\dots$ voraus.

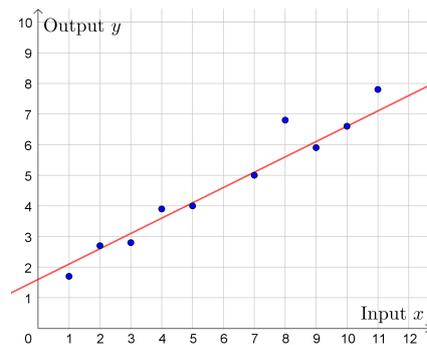
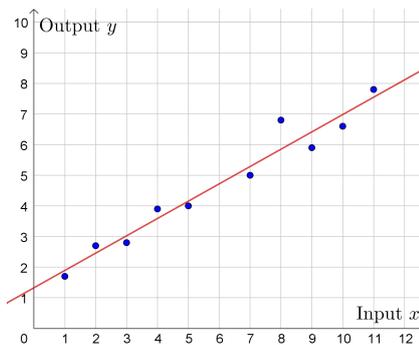
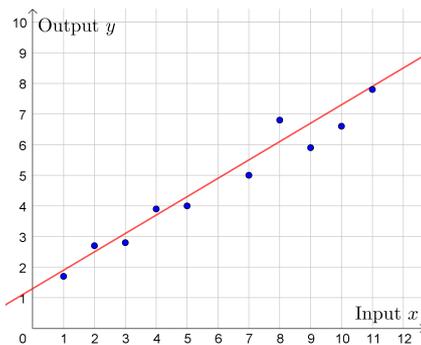
An den Stellen $x = 0,1$ und $x = 10,5$ macht diese Polynomfunktion aber vermutlich *keine* guten Voraussagen.



Lineare Regression  **MmF**

Bei **linearer Regression** legen wir die *bestmögliche* lineare Funktion durch die Punktwolke.

Welche der 3 dargestellten linearen Funktionen passt aus deiner Sicht am besten?



Wir sind auf der Suche nach *einer* Gerade, die den Zusammenhang zwischen Input und Output unter Berücksichtigung aller Messpunkte *am besten* beschreibt.

Rechts haben wir eine Gerade $y = k \cdot x + d$ durch die Punktwolke gelegt.

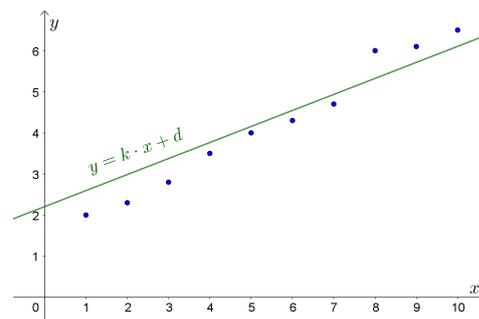
Die eingezeichnete Gerade ist gut, aber nicht perfekt.

Sollen wir die Steigung k größer oder kleiner wählen?

Sollen wir die Gerade vertikal verschieben?

Dazu müssen wir festlegen, was wir mit *am besten* meinen.

Wie sollen wir den „Fehler“ quantifizieren?

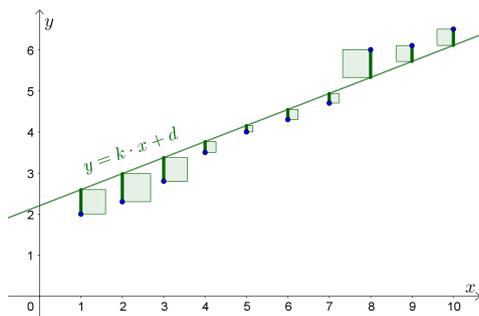


Um die sogenannte **Fehlerquadratsumme** zu ermitteln, berechnen wir zuerst die vertikalen Abstände der Messpunkte von der Gerade:

0,595	0,685	0,575	0,265	0,155
0,245	0,235	0,675	0,385	0,395

Die **Fehlerquadratsumme** F ist die Summe der Quadrate dieser Abstände.

Links siehst du die Fehlerquadrate veranschaulicht.



Für die Fehlerquadratsumme dieser Gerade gilt: $F = 0,595^2 + 0,685^2 + \dots + 0,395^2 = 2,12325$

Die Fehlerquadratsumme hängt von der Gerade ab, die wir durch die Punktwolke legen. $F(k; d)$

Je kleiner die Fehlerquadratsumme, desto besser ist die Gerade an die Punktwolke angepasst.

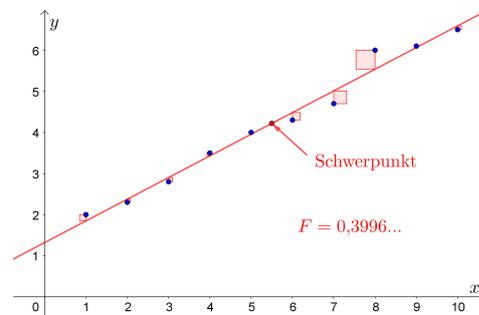
Die *bestmögliche* Gerade ist jene mit der kleinsten Fehlerquadratsumme.

Man kann die beiden folgenden Aussagen beweisen:

- 1) Zu jeder Punktwolke mit n Punkten gibt es *genau eine* bestmögliche Gerade ($n \geq 2$).
- 2) Diese bestmögliche Gerade verläuft durch den **Schwerpunkt** $(\bar{x} | \bar{y})$ der Punktwolke.

\bar{x} ist das **arithmetische Mittel** der x -Koordinaten aller Messpunkte.

\bar{y} ist das **arithmetische Mittel** der y -Koordinaten aller Messpunkte.



Diese Gerade durch die Punktwolke mit der kleinsten Fehlerquadratsumme heißt **Regressionsgerade**.

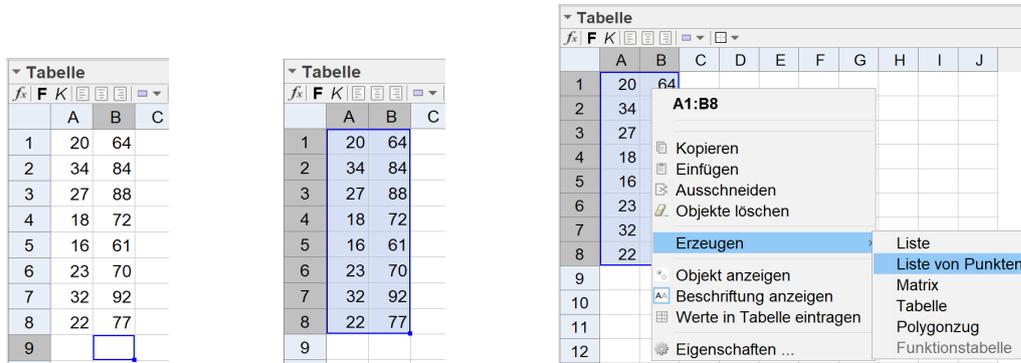
Die zugehörige lineare Funktion heißt **lineare Ausgleichsfunktion**.

Von einer Schülergruppe wurden die jeweilige Lernzeit (in Minuten) und die erreichte Punktezahl bei einer Leistungsüberprüfung notiert:

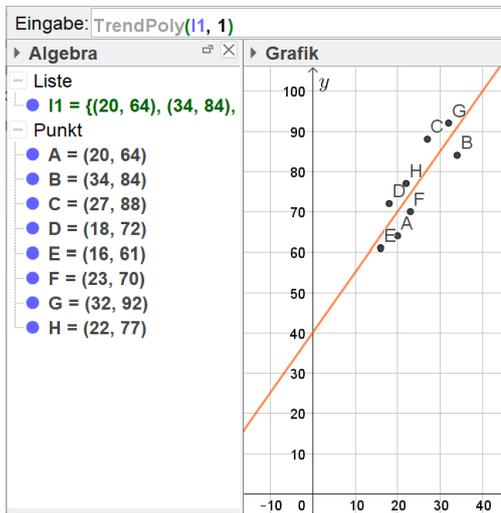
Lernzeit in Minuten	20	34	27	18	16	23	32	22
erreichte Punktezahl	64	84	88	72	61	70	92	77

- 1) Ermitteln Sie die Gleichung der zugehörigen Regressionsgeraden. (Die erreichte Punktezahl soll in Abhängigkeit von der Lernzeit beschrieben werden.)
- 2) Interpretieren Sie die Steigung der Regressionsgeraden in diesem Sachzusammenhang.
- 3) Berechnen Sie mithilfe dieses Modells, welche Punktezahl man erwarten kann, wenn man 30 Minuten lernt.

- i) Tabellenansicht öffnen (Ansicht → Tabelle)
- ii) Daten eingeben (Unabhängige Größe x in Spalte A, Abhängige Größe y in Spalte B)
- iii) Daten markieren → Rechtsklick → Erzeugen → Liste von Punkten



iv) Lineare Ausgleichsfunktion ermitteln: **TrendPoly**(<Liste von Punkten>, <Grad des Polynoms>)



1) $f(x) =$

2) Interpretation der Steigung:

3) Punktezahl bei 30 Minuten Lernzeit:

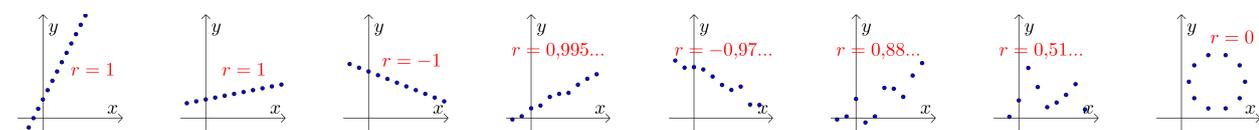
Korrelationskoeffizient nach Pearson 

$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ sind n Wertepaare. \bar{x} bzw. \bar{y} ist das arithmetische Mittel der x_i bzw. y_i . Der empirische Korrelationskoeffizient r misst den Grad des linearen Zusammenhangs.

Er hat folgende Eigenschaften:

- $-1 \leq r \leq 1$
- $r = 1 \iff$ Alle Punkte liegen auf einer Gerade mit positiver Steigung.
- $r = -1 \iff$ Alle Punkte liegen auf einer Gerade mit negativer Steigung.
- Ein Korrelationskoeffizient nahe bei 1 bzw. -1 bedeutet einen starken positiven bzw. negativen linearen Zusammenhang. Sprechweise: „Die Daten korrelieren.“

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}}$$



 **KorrelationsKoeffizient**(<Liste von Punkten>)

