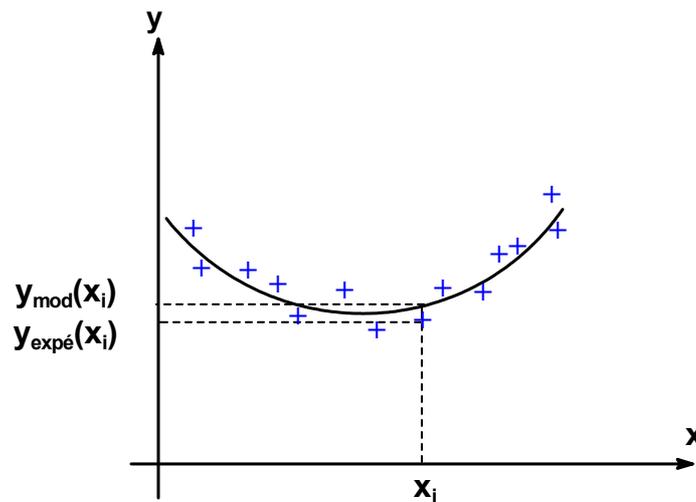


Régression polynomiale

Mise en œuvre de la regression parabolique :

Soit $\hat{y} = \hat{a}_2 x^2 + \hat{a}_1 x + \hat{a}_0$ l'équation de la parabole optimale pour N points.
Ce polynôme est obtenu par la méthode des moindres carrés .



Cette parabole est telle que la somme S des carrés des différences $[y_i(\text{expé}) - y_i(\text{modèle})]$ soit minimale.

$$S = \sum_i \left[y_{i(\text{expé})} - (\hat{a}_2 x_i^2 + \hat{a}_1 x_i + \hat{a}_0) \right]^2$$

$$\left\{ \begin{array}{l} \frac{dS}{d\hat{a}_2} = -2 \sum_i (x_i^2 y_i) + 2\hat{a}_2 \sum_i x_i^4 + 2\hat{a}_1 \sum_i x_i^3 + 2\hat{a}_0 \sum_i x_i^2 = 0 \quad (1) \\ \frac{dS}{d\hat{a}_1} = -2 \sum_i (x_i y_i) + 2\hat{a}_2 \sum_i x_i^3 + 2\hat{a}_1 \sum_i x_i^2 + 2\hat{a}_0 \sum_i x_i = 0 \quad (2) \\ \frac{dS}{d\hat{a}_0} = -2 \sum_i y_i + 2\hat{a}_2 \sum_i x_i^2 + 2\hat{a}_1 \sum_i x_i + 2\hat{a}_0 N = 0 \quad (3) \end{array} \right.$$

On en tire :

$$\begin{cases} \hat{a}_2 \sum_i x_i^4 + \hat{a}_1 \sum_i x_i^3 + \hat{a}_0 \sum_i x_i^2 = \sum_i (x_i^2 y_i) & (1') \\ \hat{a}_2 \sum_i x_i^3 + \hat{a}_1 \sum_i x_i^2 + \hat{a}_0 \sum_i x_i = \sum_i (x_i y_i) & (2') \\ \hat{a}_2 \sum_i x_i^2 + \hat{a}_1 \sum_i x_i + \hat{a}_0 N = \sum_i y_i & (3') \end{cases}$$

soit sous forme matricielle :

$$\begin{pmatrix} \hat{a}_2 \\ \hat{a}_1 \\ \hat{a}_0 \end{pmatrix} \times \begin{pmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{pmatrix} = \begin{pmatrix} \hat{a}_2 \\ \hat{a}_1 \\ \hat{a}_0 \end{pmatrix} \times |M| = \begin{pmatrix} \sum_i x_i^2 y_i \\ \sum_i x_i y_i \\ \sum_i y_i \end{pmatrix}$$

dont on tire :

$$\hat{a}_2 = \frac{\begin{pmatrix} \sum_i (x_i^2 y_i) & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i (x_i y_i) & \sum_i x_i^2 & \sum_i x_i \\ \sum_i y_i & \sum_i x_i & N \end{pmatrix}}{\begin{pmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{pmatrix}} \quad \hat{a}_1 = \frac{\begin{pmatrix} \sum_i x_i^4 & \sum_i (x_i^2 y_i) & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i (x_i y_i) & \sum_i x_i \\ \sum_i x_i^2 & \sum_i y_i & N \end{pmatrix}}{\begin{pmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{pmatrix}}$$

$$\hat{a}_0 = \frac{\begin{vmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i (x_i^2 y_i) \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i (x_i y_i) \\ \sum_i x_i^2 & \sum_i x_i & \sum_i y_i \end{vmatrix}}{\begin{vmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{vmatrix}}$$

$$D = \sum_i x_i^4 \left(N \sum_i x_i^2 - \left[\sum_i x_i \right]^2 \right) - \sum_i x_i^3 \left(N \sum_i x_i^3 - \sum_i x_i^2 \sum_i x_i \right) + \sum_i x_i^2 \left(\sum_i x_i \sum_i x_i^3 - \left[\sum_i x_i^2 \right]^2 \right)$$

$$\hat{a}_2 = \frac{\sum_i x_i^2 y_i \left(N \sum_i x_i^2 - \left[\sum_i x_i \right]^2 \right) - \sum_i x_i^3 \left(N \sum_i x_i y_i - \sum_i x_i \sum_i y_i \right) + \sum_i x_i^2 \left(\sum_i x_i y_i \sum_i x_i - \sum_i y_i \sum_i x_i^2 \right)}{D}$$

$$\hat{a}_1 = \frac{\sum_i x_i^4 \left(N \sum_i x_i y_i - \sum_i x_i \sum_i y_i \right) - \sum_i x_i^2 y_i \left(N \sum_i x_i^3 - \sum_i x_i^2 \sum_i x_i \right) + \sum_i x_i^2 \left(\sum_i y_i \sum_i x_i^3 - \sum_i x_i y_i \sum_i x_i^2 \right)}{D}$$

$$\hat{a}_0 = \frac{\sum_i x_i^4 \left(\sum_i x_i^2 \sum_i y_i - \sum_i x_i \sum_i x_i y_i \right) - \sum_i x_i^3 \left(\sum_i x_i^3 \sum_i y_i - \sum_i x_i^2 \sum_i x_i y_i \right) + \sum_i x_i^2 y_i \left(\sum_i x_i \sum_i x_i^3 - \left(\sum_i x_i^2 \right)^2 \right)}{D}$$

Variances de a_2 , a_1 et a_0

Les variances sont les termes diagonaux de la matrice V :

$$V = \begin{vmatrix} \text{var}(\hat{a}_2) & \text{cov}(\hat{a}_2, \hat{a}_1) & \text{cov}(\hat{a}_2, \hat{a}_0) \\ \text{cov}(\hat{a}_1, \hat{a}_2) & \text{var}(\hat{a}_1) & \text{cov}(\hat{a}_1, \hat{a}_0) \\ \text{cov}(\hat{a}_0, \hat{a}_2) & \text{cov}(\hat{a}_0, \hat{a}_1) & \text{var}(\hat{a}_0) \end{vmatrix}$$

Cette matrice V est telle que : $|V| = s_y^2 |M|^{-1}$ avec :

$$M = \begin{vmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{vmatrix}$$

$$\begin{aligned} \text{Det}|M| &= \sum_i x_i^4 \begin{vmatrix} \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i & N \end{vmatrix} - \sum_i x_i^3 \begin{vmatrix} \sum_i x_i^3 & \sum_i x_i \\ \sum_i x_i^2 & N \end{vmatrix} + \sum_i x_i^2 \begin{vmatrix} \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^2 & \sum_i x_i \end{vmatrix} \\ &= \sum_i x_i^4 \left[N \sum_i x_i^2 - \left(\sum_i x_i \right)^2 \right] - \sum_i x_i^3 \left[N \sum_i x_i^3 - \sum_i x_i \sum_i x_i^2 \right] + \sum_i x_i^2 \left[N \sum_i x_i^3 \sum_i x_i - \left(\sum_i x_i^2 \right)^2 \right] \end{aligned}$$

Exercice RegPoly1 :

Effectuer une régression parabolique sur les données relatives à l'indice de réfraction n de mélanges eau-glucose : $n=a_0+a_1x+a_2x^2$ (x désigne le titre (fraction) massique exprimé en % de glucose) pour déterminer les valeurs de \hat{a}_0 , \hat{a}_1 et \hat{a}_2 .

On utilisera la fonction SOMMEPROD() d'EXCEL pour calculer les expressions du type : $\sum_i x_i^4$, $\sum_i x_i^3$, ..., $\sum_i x_i^2 y_i$.

$$\text{La matrice } M = \begin{vmatrix} \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^2 & \sum_i x_i & N \end{vmatrix}$$

sera inversée en utilisation la fonction INVERSEMAT d'EXCEL.

Déterminer les valeurs σ_{a_0} , σ_{a_1} et σ_{a_2} des écarts-types de a_0 , a_1 et a_2 .

σ_{a_0} , σ_{a_1} et σ_{a_2} sont les éléments diagonaux de $\sigma_y^2 \times |M|^{-1}$.

- En déduire $a_0 = a_{0MC} \pm \Delta a_{0MC}$

$$a_1 = a_{1MC} \pm \Delta a_{1MC}$$

$$a_2 = a_{2MC} \pm \Delta a_{2MC}$$

avec un intervalle de confiance de 95%.

- La quantité $\frac{a_2 - \hat{a}_2}{\sigma_{a_2}}$ suit une loi de Student à $N-3$ degrés de liberté. On pourra tester l'hypothèse $a_2 = 0$ pour savoir si a_2 a une contribution significative dans la régression. Dans l'exemple envisagé ici :

$$\hat{a}_2 = 6,19 \times 10^{-6}$$

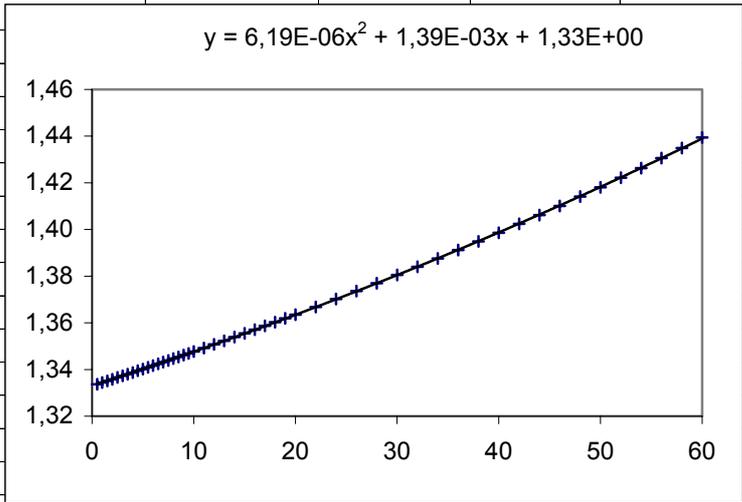
$$\sigma_{a_2} = 5,85 \times 10^{-8}$$

Sous l'hypothèse $a_2 = 0$, $\frac{a_2 - \hat{a}_2}{\sigma_{a_2}} = \frac{-6,19 \times 10^{-6}}{5,85 \times 10^{-8}} = -106$. La probabilité d'observer une

valeur supérieure à 106 en valeur absolue pour une variable de Student à $50-3=47$ degrés de liberté est très faible, ce qui amène à rejeter l'hypothèse de nullité de a_2 .

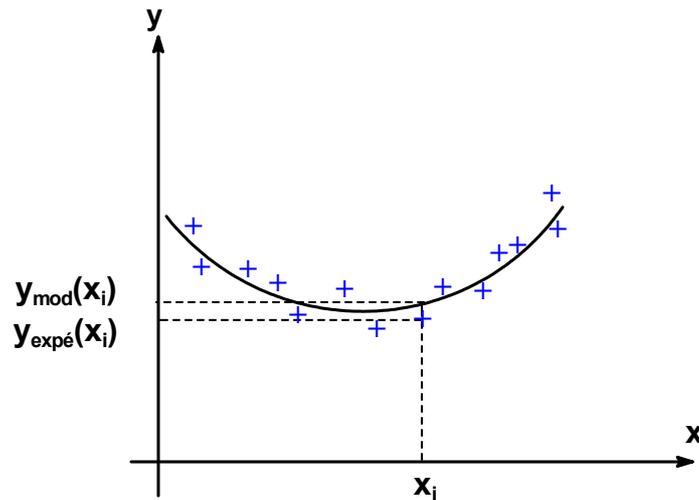
	A	B	C	D	E	F	G	H
1	Indice de réfraction d'une sol aq de glucose $n=a_2*x^2+a_1*x+a_0$							
2								
3		8,47E+07	1,75E+06	3,95E+04	S			
4	M=	1,75E+06	3,95E+04	1,08E+03	5,58E-07	a₂	a₁	a₀
5		3,95E+04	1,08E+03	50		6,19E-06	1,394E-03	1,33
6					σ(y)	σ(a₂)	σ(a₁)	σ(a₀)
7		2,88E-07	-1,60E-05	1,19E-04	1,09E-04	5,85E-08	3,37E-06	3,41E-05
8	M⁻¹=	-1,60E-05	9,54E-04	-7,95E-03				
9		1,19E-04	-7,95E-03	9,80E-02		1,06E+02		
10								
11								
12	Sx	Sy	Sx4	Sx3	Sx2			
13	1080,00	68,40	8,47E+07	1,75E+06	3,95E+04			
14	D	Sxy	Sx2y	N				
15	2,81E+12	1,51E+03	5,56E+04	50				
16	x	y						ycalculé
17	0,5000	1,3337						1,3338
18	1,0000	1,3344						1,3345
19	1,5000	1,3351						1,3352
20	2,0000	1,3358						1,3359
21	2,5000	1,3366						1,3366
22	3,0000	1,3373						1,3373
23	3,5000	1,3380						1,3381
24	4,0000	1,3387						1,3388
25	4,5000	1,3395						1,3395
26	5,0000	1,3402						1,3402
27	5,5000	1,3409						1,3410
28	6,0000	1,3417						1,3417
29	6,5000	1,3424						1,3424
30	7,0000	1,3432						1,3432
31	7,5000	1,3439						1,3439
32	8,0000	1,3447						1,3446
33	8,5000	1,3454						1,3454
34	9,0000	1,3462						1,3461
35	9,5000	1,3469						1,3469
36	10,0000	1,3477						1,3477

Quotient $a_2/\sigma(a_2)$
Ici la valeur de ce quotient justifie une regression parabolique plutot que linéaire



Régression polynomiale : Mise en œuvre de la régression cubique

Soit $y = a_3x^3 + a_2x^2 + a_1x + a_0$ l'équation utilisée pour estimer les valeurs de y_i pour N points. Les a_i sont déterminés par la méthode des moindres carrés.



La somme S des carrés des différences $[y_i(\text{expé}) - y_i(\text{modèle})]$ doit être minimale.

$$S = \sum_{i=1}^N \left[y_i(\text{expé}) - (a_3x_i^3 + a_2x_i^2 + a_1x_i + a_0) \right]^2$$

Les valeurs des a_i sont telles que $\frac{dS}{da_i} = 0$

On en déduit :

$$\begin{cases} a_3 \sum_i x_i^6 + a_2 \sum_i x_i^5 + a_1 \sum_i x_i^4 + a_0 \sum_i x_i^3 = \sum_i (x_i^3 y_i) & (1') \\ a_3 \sum_i x_i^5 + a_2 \sum_i x_i^4 + a_1 \sum_i x_i^3 + a_0 \sum_i x_i^2 = \sum_i (x_i^2 y_i) & (2') \\ a_3 \sum_i x_i^4 + a_2 \sum_i x_i^3 + a_1 \sum_i x_i^2 + a_0 \sum_i x_i = \sum_i (x_i y_i) & (3') \\ a_3 \sum_i x_i^3 + a_2 \sum_i x_i^2 + a_1 \sum_i x_i + a_0 N = \sum_i y_i & (4') \end{cases}$$

soit sous forme matricielle :

$$\begin{array}{c} \left| \begin{array}{c} a_3 \\ a_2 \\ a_1 \\ a_0 \end{array} \right| \end{array} \times \begin{array}{cccc} \left| \begin{array}{c} \sum_i x_i^6 \\ \sum_i x_i^5 \\ \sum_i x_i^4 \\ \sum_i x_i^3 \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^5 \\ \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \\ N \end{array} \right| \end{array} = \begin{array}{c} \left| \begin{array}{c} a_3 \\ a_2 \\ a_1 \\ a_0 \end{array} \right| \end{array} \times |M| = \begin{array}{c} \left| \begin{array}{c} \sum_i x_i^3 y_i \\ \sum_i x_i^2 y_i \\ \sum_i x_i y_i \\ \sum_i y_i \end{array} \right|$$

On en déduit :

$$a_3 = \frac{\begin{array}{cccc} \left| \begin{array}{c} \sum_i x_i^3 y_i \\ \sum_i x_i^2 y_i \\ \sum_i x_i y_i \\ \sum_i y_i \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^5 \\ \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \\ N \end{array} \right| \\ \left| \begin{array}{c} \sum_i x_i^6 \\ \sum_i x_i^5 \\ \sum_i x_i^4 \\ \sum_i x_i^3 \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^5 \\ \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^4 \\ \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \end{array} \right| & \left| \begin{array}{c} \sum_i x_i^3 \\ \sum_i x_i^2 \\ \sum_i x_i \\ N \end{array} \right| \end{array}$$

$$\begin{aligned}
 a_2 &= \frac{
 \begin{array}{|c|c|c|c|}
 \hline
 \sum_i x_i^6 & \sum_i x_i^3 y_i & \sum_i x_i^4 & \sum_i x_i^3 \\
 \hline
 \sum_i x_i^5 & \sum_i x_i^2 y_i & \sum_i x_i^3 & \sum_i x_i^2 \\
 \hline
 \sum_i x_i^4 & \sum_i x_i y_i & \sum_i x_i^2 & \sum_i x_i \\
 \hline
 \sum_i x_i^3 & \sum_i y_i & \sum_i x_i & N \\
 \hline
 \end{array}
 }{
 \begin{array}{|c|c|c|c|}
 \hline
 \sum_i x_i^6 & \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 \\
 \hline
 \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\
 \hline
 \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\
 \hline
 \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i & N \\
 \hline
 \end{array}
 } \\
 a_1 &= \frac{
 \begin{array}{|c|c|c|c|}
 \hline
 \sum_i x_i^6 & \sum_i x_i^5 & \sum_i x_i^3 y_i & \sum_i x_i^3 \\
 \hline
 \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^2 y_i & \sum_i x_i^2 \\
 \hline
 \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i y_i & \sum_i x_i \\
 \hline
 \sum_i x_i^3 & \sum_i x_i^2 & \sum_i y_i & N \\
 \hline
 \end{array}
 }{
 \begin{array}{|c|c|c|c|}
 \hline
 \sum_i x_i^6 & \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 \\
 \hline
 \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\
 \hline
 \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\
 \hline
 \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i & N \\
 \hline
 \end{array}
 }
 \end{aligned}$$

$$a_0 = \frac{\begin{vmatrix} \sum_i x_i^6 & \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 y_i \\ \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 y_i \\ \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i y_i \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i & \sum_i y_i \end{vmatrix}}{\begin{vmatrix} \sum_i x_i^6 & \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 \\ \sum_i x_i^5 & \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 \\ \sum_i x_i^4 & \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i \\ \sum_i x_i^3 & \sum_i x_i^2 & \sum_i x_i & N \end{vmatrix}}$$