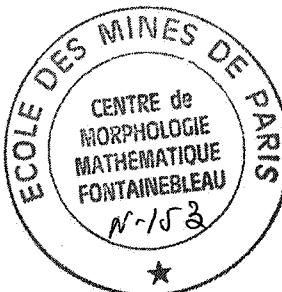


G. Matheson
1963



COMPARAISON DES ECHANTILLONNAGES MINE ET USINE A MONVILLE

1.- Résultats

La comparaison porte sur trois listes de résultats, marquées A, B et C. La liste C donne les résultats de l'échantillonnage mine analysé à la mine. La liste A donne le résultat de l'analyse faite au laboratoire de l'usine sur la même pâtre de 100 g analysée par ailleurs à la mine (liste C) : ainsi la comparaison de A et C ne concerne que les opérations de laboratoire, et non pas l'échantillonnage proprement dit.

La liste B, enfin, donne les résultats des analyses faites à l'usine sur les produits obtenus par l'échantillonnage continu effectué à l'usine. Le contenu de chaque carnet de minéral est, en principe, caractérisé par trois chiffres A,B,C. Dans la suite, nous désignons par A_1 , B_1 et C_1 les résultats relatifs au convoi N°1. Les séries chronologiques A_2 , B_2 et C_2 étaient disponibles pour les mois de Janvier à Septembre 1963, (avec un à trois mois quotidiens). En fait, nous avons dû renoncer à utiliser les données relatives aux trois premiers mois, pour lesquels les séries A_1 et C_1 présentent des interversions manifestes (correspondant à des confusions dans l'attribution des deux chiffres quotidiens aux deux convois correspondants).

2.- Méthode, et résumé des résultats.

La méthode de travail utilisée consiste dans l'analyse des auto-corrélations des séries chronologiques A,B, et C et des corrélations croisées. Les résultats sont les suivants :

a/. Les deux séries A et C (analysées d'une même pâtre par l'usine et la mine respectivement) sont en très bon accord. Elles ne comportent pas de divergence systématique. La précision du laboratoire de l'usine ($\pm 0,64\%$) est légèrement supérieure à celle du laboratoire de la mine ($\pm 0,86\%$).

... / ...

b/... Les deux séries A et B présentent une différence systématique. La valeur moyenne de $A_1 - B_1$ est de l'ordre de + 0,4, valeur significative statistiquement, correspondant à une divergence systématique.

c/... L'examen des variances montre une première anomalie. La variance de A(1,26) est notablement plus faible que celle de B(2,03). Si les deux modes de prélevement étaient corrects, la variance du dispositif continu B devrait être plus faible que celle du dispositif A.

d/... L'examen des auto-corrélations met en évidence une deuxième anomalie. La série A_1 ne présente que des autocorrelations nulles ou négligeables : entre un convoi i et celui qui le précède ou le suit, les analyses A_i et A_{i+1} sont pratiquement sans corrélation : tout se passe ici comme si chaque convoi était à peu près indépendant de ceux qui le précèdent ou le suivent.

Au contraire, la série des B_i a de très fortes autocorrelations. L'analyse B_1 du convoi i a tendance à être supérieure à la moyenne lorsque l'analyse B_{i-1} du convoi précédent a donné un résultat élevé, et réciproquement. Plus généralement, B_i et B_{i+n} présentent des corrélations sensibles jusqu'à vers $n = 10$. À raison de deux convois par jour en moyenne, on voit que ces influences s'étendent sur une période de l'ordre de 5 jours.

Ainsi les images A_i et B_i d'un même phénomène (le convoi i) sont contradictoires entre elles et incompatibles. L'image fournie par B est celle d'un phénomène structuré dans le temps (évoluant dans le temps avec un certain degré de continuité), tandis que A n'évoque aucune structure, mais plutôt une succession d'erreurs d'analyse et de prélevements aléatoires et indépendantes les unes des autres.

On peut penser (mais sans avoir le droit de l'affirmer) que la structure révélée par la série B n'est pas une propriété des convois eux-mêmes, mais un phénomène provoqué ajouté par le dispositif d'échantillonnage continu : elle pourrait correspondre à une dérive systématique dans le temps du réglage des appareils, dérive qui serait rectifiée à intervalles plus ou moins réguliers par une renise au

point de ce réglage : celle pourrait être l'origine de la période de 5 jours qui régit ces autocorrelations.

e/- L'examen des corrélations croisées permet de préciser les conclusions précédentes. En premier lieu, la corrélation entre les chiffres A_j et B_j relatifs à un même convoi est extrêmement faible, mais positive (coefficients de corrélation de + 0,15). Ce chiffre confirme qu'il n'y a qu'un rapport lointain entre A_j et B_j , mais que ce rapport existe.

En deuxième lieu, nous avons examiné les corrélations croisées, c'est-à-dire les corrélations entre B_j et A_{j+k} et entre B_j et A_{j+10} . Une dissymétrie brutale est apparue, qui doit traduire un lien de causalité :

- Entre B_j et A_{j+1} , A_{j+2} (c'est-à-dire entre le chiffre usine relatif au convoi j et les chiffres mines relatifs aux convois suivants $j+1$, $j+2...$) les corrélations sont négligeables (- 0,04, - 0,03), de sorte que B_j est indépendant de A_{j+1} , A_{j+2} ...

- Au contraire, entre B_j et A_{j-1} , A_{j-2} ... A_{j-10} (c'est-à-dire entre le chiffre usine relatif au convoi j et les chiffres mines relatives à chacun des 10 convois précédents) apparaissent des corrélations toutes positives. Chacune d'elles est relativement faible (coefficients variant de + 0,10 à + 0,20), mais, prises dans leur ensemble, elles constituent un phénomène très significatif.

Cette dissymétrie dans le temps doit s'interpréter par un lien de causalité. Tout ce passe comme si B_j reflétait non pas la teneur t_j du convoi j seul, mais une moyenne pondérée du convoi j et des 10 convois antérieurs. Ceci suggère une interprétation simple : le minerai séjournerait dans l'appareil, de sorte que le préliminaire attribué au convoi j serait en réalité un mélange complexe de minerais provenant des convois antérieurs.

f/- Ces résultats suggèrent l'interprétation suivante. Désignant par t_j la teneur moyenne zérole (inconnue) du convoi j , les chiffres mines et usine

seraient donnés par des relations de la forme :

$$\left\{ \begin{array}{l} A_1 = t_1 + e_1 \\ B_1 = \frac{1}{11} \left[t_1 + t_{1+1} + \dots + t_{1+10} \right] + e_1 \end{array} \right.$$

En ce qui concerne A_1 , chiffre nine, les e_1 seraient des erreurs d'analyse et de préliminaire, aléatoires, indépendantes les unes des autres et des t_1 . La variance des convois $\sigma_{t_1}^2$ serait de l'ordre de 0.4 (tenure des convois variant dans une fourchette de $\pm 1,5$ points), celle des e_1 de l'ordre de 0.8 (erreur d'analyse et de préliminaire de ± 2 points). Les e_1 se comportent comme des erreurs usuelles, mais on ne peut cependant pas affirmer que leur valeur moyenne soit nulle, c'est-à-dire qu'ils n'introduisent pas d'erreur systématique.

En ce qui concerne B_1 , le terme correspondant à une moyenne (en principe, une moyenne pondérée, mais, pour simplifier, nous avons pris une simple moyenne arithmétique) des 11 convois t_1 à t_{1+10} introduit une variance de l'ordre de 0.2 (tenures des 11 convois consécutifs variant dans une fourchette de ± 1 point). L'erreur e_1 a une variance très forte, de l'ordre de 1.8 (fourchette de $\pm 2,7$ points). Alors que la corrélation entre B_1 et t_1 est faible (0,15 environ), la corrélation entre B_1 et la moyenne des 11 convois est notable (0,30 environ). Cette même corrélation régne entre B_1 et la moyenne des 11 A_1 correspondants, et ce point établit que les A_1 et les B_1 se rapportent bien à un même phénomène (les tenures t_1 des convois), l'image fournie par B_1 ayant subi une certaine déformation.

De plus, B_1 dépendant des 11 convois t_1 , t_{1+1} ... t_{1+10} et B_{1+1} , par exemple, des convois t_{1+1} , t_2 ... t_{1+10} , ne rapportant, pour 10 ensembles, à un même lot de mineraux (t_1 ... t_{1+10}), et pour 1/11 seulement à un lot différent (t_{1+1} ou t_{1+10}). Ce point rend compte, en partie, de la corrélation régnant entre B_1 et B_{1+1} : mais en partie seulement.

En fait, la covariance de t_i et t_{i+1} est de 0.8, alors que l'effet de mélange des t_1, t_{i-1}, \dots ne justifie qu'une covariance de 0.2. Pour l'essentiel, (0.6 sur 0.8) cette covariance ne provient pas des t_i , mais des erreurs de ϵ_i . Il résulte que les erreurs ϵ_i de l'usine ne sont pas des erreurs de type ordinaire : elles ne sont pas indépendantes les unes des autres, mais l'erreur ϵ_i est fortement liée à l'erreur ϵ_{i-1} connue sur le travail précédent.

Cette corrélation entre erreurs successives peut sans doute s'interpréter par une dérive dans le temps du réglage des appareils (avec des révisions au point périodiques). Il est plausible (mais on ne peut l'affirmer) qu'une telle dérive soit génératrice d'une cause d'erreur systématique.

Ayant résumé l'essentiel, nous allons maintenant préciser certains détails de méthode ou de calcul.

2.- Comparaison des deux laboratoires.

Pour une même prise de teneur inconnue y , le laboratoire de l'usine donne le résultat Λ et celui de la mine G . On a

$$\left\{ \begin{array}{l} \Lambda = y + \alpha \\ G = y + \gamma \end{array} \right.$$

les erreurs α et γ étant aléatoires, indépendantes l'une de l'autre et de y , et de valeurs probables nulles (en l'absence de différence systématique des deux laboratoires).

En prenant les variances de Λ et G et la covariance AG , il vient :

$$\left\{ \begin{array}{l} \sigma_{\Lambda}^2 = \sigma_y^2 + \sigma_{\alpha}^2 \\ \sigma_G^2 = \sigma_y^2 + \sigma_{\gamma}^2 \\ \sigma_{AG}^2 = \sigma_y^2 \end{array} \right. \implies \left\{ \begin{array}{l} \sigma_{\alpha}^2 = \sigma_{\Lambda}^2 - \sigma_{AG}^2 = 0.102 \\ \sigma_{\gamma}^2 = \sigma_G^2 - \sigma_{AG}^2 = 0.184 \end{array} \right.$$

D'où les fourchettes d'erreur des labo min et max ($2 \sigma_x = \pm 0,64$) et min ($2 \sigma_y = \pm 0,66$).

4/ - Test sur la différence A₁ - B₁.

La différence $A_1 - B_1$ a une valeur moyenne de 0,4 et une variance de 2,9215, c'est-à-dire un écart type de 1,71, pour 241 échantillons. On a :

$$\frac{0,4}{1,71} \approx \sqrt{\frac{1}{241}} = 3,64$$

Cette différence de 3,6 écart type est hautement significative (Il n'y a que 1,3 chances sur 10.000 d'en observer une aussi forte si la valeur vraie est égale à 0).

5/ - Autocorrélation.

Le fait que les A_i ne présentent pas d'autocorrélation sensible ne signifie pas nécessairement que les tenues t_{ij} des couveaux successifs soient indépendantes. Il indique simplement que, si l'on écrit $A_i = t_{ij} + e_{ij}$, les erreurs aléatoires e_{ij} sont indépendantes entre elles et ont une variance nettement plus forte que les tenues réelles t_{ij} des couveaux, de sorte que l'autocorrélation des couveaux, si elle existe, est masquée à peu près entièrement par les erreurs aléatoires.

En fait, la covariance $c(A_i A_{i+1})$ a une valeur positive faible, mais à peu près significative (0,162). Comme les e_{ij} sont indépendantes des t_{ij} , on connaît donc :

$$c(t_i t_{i+1}) = c(A_i A_{i+1}) = 0,162$$

La variance des couveaux est nécessairement supérieure à ce chiffre. Elle pourrait être de l'ordre de 0,3 ou 0,4.

Un autre indication dans le même sens est fournie par les valeurs moyennes $\frac{1}{10} (A_1 + A_{1+1} + \dots + A_{1+10})$ des analyses min et max de dix couveaux consécutifs.

Ces moyennes mobiles ont une variance de 0,26, valeur nettement supérieure à celle que l'on observerait si les convois étaient indépendants ($\frac{1}{10} \sigma_t^2 = 0,125$).

Si l'on admet que les convois ont une variance σ_t^2 de l'ordre de 0,4, il reste pour la variance de l'erreur σ_e^2

$$\sigma_{e_1}^2 = \sigma_A^2 - \sigma_t^2 = 1,25 - 0,4 \neq 0,8$$

Dans une moyenne mobile par 10, la composante de la variance due aux e_i est $\frac{1}{10} 0,8 = 0,08$, et il reste $0,26 - 0,08 = 0,18$ pour la variance de la moyenne mobile des teneurs vraies. Cet ordre de grandeur est compatible avec ce que l'on peut déduire des corrélations croisées (parag. suivant). Il implique, au niveau des teneurs vraies, des corrélations assez importantes entre convois consécutifs : mais celles-ci sont complètement masquées par les erreurs aléatoires, et il n'est pas possible de les calculer à partir des données disponibles.

Au contraire, la série des B_i (échantillonnage usine) est fortement autocorrélée. La première covariance est de l'ordre de 0,8, donc notablement supérieure à la valeur attribuée ci-dessus à la variance des convois. Il en résulte que cette autocorrélation trouve sa source non pas dans le phénomène primaire (la série des teneurs vraies t_i des convois) mais dans un phénomène secondaire superposé par le dispositif d'échantillonnage continu : interprétation qui s'accorde bien avec l'hypothèse d'une dérive dans le temps du réglage de ce dispositif.

4.2. Corrélation croisée.

Le contraste entre les corrélations inexistantes dans le sens $B_i A_{i+k}$ et, au contraire, faibles mais constamment positives dans le sens $B_i A_{i-k}$ est un fait majeur. Sans faire de test précis, il suffit d'observer qu'en l'absence de corrélation vraie la probabilité d'observer une séquence de 10 coefficients positifs serait $2^{10} \neq 10^{-3}$, soit 1/1000 environ. Ce fait implique une relation causale. Naturellement, les A_{i-k} ne peuvent pas être la cause directe de B_i , mais n'influent sur lui que par l'intermédiaire des teneurs vraies t_{i-k} des convois. Comme $A_i = t_i + e_i$,

les a_k étant indépendants des t_k , et par suite aussi des B_k , la covariance des $A_{j,k}$ avec les B_k ne diffère pas de celle des $t_{j,k}$ avec les mêmes B_k :

$$\sigma(A_{j,k}, B_k) = \sigma(t_{j,k}, B_k)$$

La théorie de la régression linéaire montre que B_k doit être de la forme :

$$B_k = C_k + a_0 t_k + a_1 t_{k-1} + \dots$$

c'est-à-dire la somme d'une erreur ϵ_k indépendante des t_k et d'une combinaison linéaire des $t_{j,k}$: d'où l'idée que l'usine n'échantillonne pas le convoi t_k mais un mélange de tous les convois antérieurs.

Un calcul précis des coefficients a_0, a_1, \dots n'aurait pas grand sens, du fait que les covariances expérimentales, faibles vis-à-vis des variances, sont entachées d'importantes fluctuations aléatoires. (les corrélations entre convois sont masquées par les erreurs aléatoires). On peut tout au plus chercher à dégager des ordres de grandeur. Observant que les corrélations $\sigma(B_k A_{j,k})$ sont notables de $k=0$ à $k=10$, et changent ensuite d'allure et d'ordre de grandeur, on peut admettre, en première approximation, que les B_k ne dépendent que des 11 convois $t_k, t_{k-1}, \dots, t_{k-10}$ antérieurs, et, puisque l'on renonce au calcul précis des a_k , qu'ils ne dépendent que de la moyenne arithmétique de ces convois

$$y_k = \frac{1}{11} [t_k + t_{k-1} + \dots + t_{k-10}]$$

étant entendu que cette hypothèse simpliste est simplement destinée à mettre en évidence un ordre de grandeur. Dans ces conditions, B_k sera de la forme :

$$B_k = \lambda y_k + \epsilon_k$$

Nous prendrons en fait $\lambda = 1$: en premier lieu, parce qu'il est plausible que B_k ne diffère de la teneur y_k échantillonnée que par une erreur ϵ_k indépendante de y_k . En deuxième lieu, parce que la moyenne

$$\frac{1}{11} \sum_{k=0}^{10} \sigma(B_k A_{j,k}) = 0,22$$

des covariances croisées doit être égale à $\lambda^2 \sigma_y^2$ et que la variance σ_y^2 des y_i est - nous l'avons vu - de l'ordre de 0,2, d'où $\lambda \approx 1$.

5.- Interprétation (conjecturale)

On arrive ainsi à l'idée que A_1 et B_1 soient de la forme :

$$\left\{ \begin{array}{l} A_1 = e_1 + t_1 \\ B_1 = e_1 + \frac{1}{11} \sum_{k=0}^{10} t_{1+k} \end{array} \right.$$

Les e_1 - erreurs de prélèvement et d'analyse de la mine - sont indépendantes les unes des autres, des t_1 et des e_1 . Les t_1 présentent des autocorrélations, mais sont indépendants des erreurs e_1 et e_1 .

Par contre les erreurs e_1 de l'usine ne peuvent pas être indépendantes les unes des autres. En effet, la covariance $\sigma(e_1 B_{1+1}) = 0,94$ est de la forme :

$$\sigma_{e_1 B_{1+1}} = \sigma_{e_1 e_{1+1}} + \sigma_{y_1 y_{1+1}}$$

Or la covariance $\sigma_{y_1 y_{1+1}}$ est majorée par la variance $\sigma_{y_1}^2$, qui est de l'ordre de 0,2. Il reste donc :

$$\sigma_{e_1 e_{1+1}} > 0,94 - 0,2 \approx 0,6$$

L'autocorrélation des erreurs de prélèvement à l'usine s'interprète convenablement par l'hypothèse d'une dérive dans le temps du réglage des appareils (mais cela ne constitue pas une démonstration formelle).

La variance $\sigma_B^2 = 2,03$ des B_1 est la somme de la variance $\sigma_y^2 \approx 0,2$ des couvois mélangés et de la variance de l'erreur e_1 :

$$\sigma_{e_1}^2 \approx 1,8$$

Cette valeur de 1,6 est forte, vis-à-vis de la première covariance $\sigma_{e_1 e_{1+1}}$ qui est de l'ordre de 0,6. On peut en déduire l'idée que l'erreur ϵ_1 de l'usine est la somme d'une erreur aléatoire de type usuel η_1 et d'un terme d_1 reflétant la dérive (responsable de la totalité de l'autocorrélation des ϵ_1), soit :

$$\epsilon_1 = \eta_1 + d_1$$

Comme $\sigma_{d_1 d_{1+1}} = \sigma_{\epsilon_1 \epsilon_{1+1}} \approx 0,6$, on peut penser que la variance du terme de dérive est de l'ordre de 0,8 à 0,9. D'où :

$$\sigma_{d_1}^2 \approx \sigma_{\eta_1}^2 \approx 0,9$$

Dérive et composante aléatoire seraient d'un ordre de grandeur comparable.

G. MATHIEU
25 Novembre 1963.

TABLEAU DES VALEURS NUMÉRIQUES EXPÉRIMENTALES

A/ - Variances et covariances (calculées sur 241 échantillons).

$$\left\{ \begin{array}{l} \sigma_A^2 = 1.2305 \\ \sigma_B^2 = 2.0256 \\ \sigma_C^2 = 1.3409 \end{array} \right. \quad \left\{ \begin{array}{l} \sigma_{AB} = 0.1813 \\ \sigma_{BC} = 0.1397 \\ \sigma_{CA} = 1.1966 \end{array} \right. \quad \left\{ \begin{array}{l} p_{AB} = + 0.125 \\ p_{BC} = + 0.103 \\ p_{CA} = + 0.89 \end{array} \right.$$

B/ - Covariances et autocorrelations des A_j et des B_j

$$\begin{aligned} \sigma(B_1 B_{1+1}) &= 0.3981 & \longrightarrow & p_1 = 0.413 \\ \sigma(B_1 B_{1+2}) &= 0.3951 & \longrightarrow & p_2 = 0.296 \\ \sigma(B_1 B_{1+3}) &= 0.4533 & \longrightarrow & p_3 = 0.224 \\ \sigma(B_1 B_{1+4}) &= 0.3762 & \longrightarrow & p_4 = 0.185 \\ \sigma(B_1 B_{1+5}) &= 0.3493 & \longrightarrow & p_5 = 0.173 \\ \sigma(B_1 B_{1+6}) &= 0.0463 & \longrightarrow & p_6 = 0.024 \\ \sigma(B_1 B_{1+10}) &= 0.1050 & \longrightarrow & p_{10} = 0.052 \end{aligned}$$

$$\begin{aligned} \sigma(A_1 A_{1+1}) &\approx + 0.1624 & \longrightarrow & p_1 \approx + 0.329 \\ \sigma(A_1 A_{1+2}) &\approx - 0.0594 & \longrightarrow & p_2 \approx - 0.040 \\ \sigma(A_1 A_{1+3}) &\approx - 0.0401 & \longrightarrow & p_3 \approx - 0.032 \\ \sigma(A_1 A_{1+4}) &\approx + 0.1373 & \longrightarrow & p_4 \approx + 0.203 \\ \sigma(A_1 A_{1+5}) &\approx + 0.1086 & \longrightarrow & p_5 \approx + 0.087 \\ \sigma(A_1 A_{1+6}) &\approx + 0.1163 & \longrightarrow & p_6 \approx + 0.093 \end{aligned}$$

a/ Covariances et corrélations croisées.

$$\left\{ \begin{array}{l} \sigma(B_1 A_{j+2}) = -0.096 \rightarrow p_{-2} = -0.060 \\ \sigma(B_1 A_{j+1}) = -0.051 \rightarrow p_{-1} = -0.072 \\ \\ \sigma(B_1 A_j) = +0.1813 \rightarrow p_0 = +0.113 \\ \\ \sigma(B_1 A_{j+1}) = +0.2350 \rightarrow p_1 = +0.246 \\ \sigma(B_1 A_{j+2}) = +0.3209 \rightarrow p_2 = +0.205 \\ \sigma(B_1 A_{j+3}) = +0.3296 \rightarrow p_3 = +0.205 \\ \sigma(B_1 A_{j+4}) = +0.2500 \rightarrow p_4 = +0.093 \\ \sigma(B_1 A_{j+5}) = +0.2484 \rightarrow p_5 = +0.092 \\ \sigma(B_1 A_{j+6}) = +0.1999 \rightarrow p_6 = +0.125 \\ \sigma(B_1 A_{j+7}) = +0.1530 \rightarrow p_7 = +0.095 \\ \sigma(B_1 A_{j+8}) = +0.3439 \rightarrow p_8 = +0.214 \\ \sigma(B_1 A_{j+9}) = +0.0991 \rightarrow p_9 = +0.062 \\ \sigma(B_1 A_{j+10}) = +0.2665 \rightarrow p_{10} = +0.166 \\ \\ \sigma(B_1 A_{j+11}) = +0.0192 \rightarrow p_{11} = +0.012 \\ \sigma(B_1 A_{j+12}) = -0.1260 \rightarrow p_{12} = -0.079 \\ \sigma(B_1 A_{j+13}) = -0.0009 \rightarrow p_{13} = -0.006 \end{array} \right.$$