

## TP de MOTUS – Génération

Nicolas Pelé

Maxim Peveri

# Détermination de la loi de génération sur les données de 1995

---

Le motif sélectionné est le motif « enseignement université », en attraction et en émission. Nous allons déterminer la meilleure loi de génération, en testant différents modèles de manière progressive.

Tout d'abord, le problème d'hétéroscédasticité est présent. Il peut être traité sur les variables de population (population totale, nombre d'étudiants par exemple) mais il ne peut être traité sur des variables d'activité (comme le nombre de places étudiants).

Afin de tester la qualité de chaque régression, nous avons utilisé différents critères :

- Le  $R^2$  correspond au pourcentage de la variance initiale du nuage de points expliquée par la droite de régression. Plus le  $R^2$  est important, meilleur est la régression car plus la régression explique un pourcentage élevé de la variance. Cependant, ce  $R^2$  augmente automatiquement plus il y a de variables explicatives.
- Le  $R^2$  corrigé permet de comparer des régressions qui ne possèdent pas le même nombre de variables explicatives.
- Le F de Fisher correspond au rapport entre les carrés expliqués et les carrés non expliqués. Si la valeur critique du F de Fisher est inférieure à la valeur critique de 5%, alors on considère que la régression est significative à 95%, c'est-à-dire qu'au moins une des variables possède un coefficient non nul.
- Si le t de Student observé est supérieur au t théorique de 5% pris ici, on ne peut garder la variable concernée.
- Le signe des coefficients est important et nécessite réflexion : si le coefficient est positif, cela signifie que la variable favorise le motif. On peut alors rejeter une variable si son coefficient n'est pas logique.

## Emission :

### 1ère régression

Le premier modèle choisi consiste à prendre comme variables explicatives un maximum des variables. Nous avons donc commencé en prenant 8 variables : la "population totale", le "taux de scolaire dans le primaire", le "taux de scolaire dans le collège-lycée", le "taux d'étudiants", le "taux d'actifs ayant un emploi", le "nombre de place dans l'enseignement secondaire", le "nombre de places étudiantes" et la "motorisation".

Il faut commencer par ramener les variables de nombre de scolaire dans le primaire et dans les collèges-lycées, et d'étudiant en taux, en divisant ces chiffres par la population de la zone : cela permet de résoudre le problème l'effet de masse.

Statistiques de la régression									
Coefficient d	0,982049403								
Coefficient d	0,96421029								
Coefficient d	0,946631543								
Erreur-type	1372,01499								
Observations	25								
ANALYSE DE VARIANCE									
	Degré de liberté	Somme des carrés des cov	F	sur critique de F					
Régression	8	816115005,3	102051875,7	54,21297975	3,8475E-10				
Résidus	16	30118903,14	1882425,134						
Total	24	846533807,4							
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de confiance = 95,0%				
Constante	-15717,0874	5500,080769	-2,85761029	0,011399978	-27376,7377	-4057,43711	-27376,7377	-4057,43711	
Variable X 1	0,107414299	0,015816373	6,79133560	4,33222E-06	0,073885086	0,140943513	0,073885086	0,140943513	
Variable X 2	10654,90813	18718,18577	0,569227609	0,577106164	-29025,8728	50335,68908	-29025,8728	50335,68908	
Variable X 3	-29408,4123	14423,34341	-2,03894557	0,058330465	59984,5341	1167,709738	-59984,5341	1167,709738	
Variable X 4	111974,9792	18171,00634	6,162288269	1,3654E-05	73454,16684	150495,7916	73454,16684	150495,7916	
Variable X 5	9161,711604	11588,74536	0,790569737	0,44075642	-15405,3309	33728,75414	-15405,3309	33728,75414	
Variable X 6	0,125333935	0,13655515	0,91782649	0,372338657	-0,16415005	0,414817919	-0,16415005	0,414817919	
Variable X 7	0,060936226	0,039500788	1,54265849	0,142458947	-0,0228017	0,144674154	-0,0228017	0,144674154	
Variable X 8	10935,29895	4475,444275	2,443399643	0,026520649	1447,780979	20422,81692	1447,780979	20422,81692	

Le  $R^2$  de la régression est bon (0.9644), ce qui s'explique par le grand nombre de variables.

La valeur critique de F est excellente (3.8475E-10), ce qui signifie qu'au moins une variable possède un coefficient non nul.

Cependant les probabilités t des variables "taux de scolaire dans le primaire", "taux de scolaire dans le collège-lycée", "taux d'actifs ayant un emploi", "nombre de place dans l'enseignement secondaire" et "nombre de places étudiantes" sont supérieurs à 5%, ce qui signifie que ce ne sont pas des variables explicatives.

Par conséquent nous gardons les variables "population totale", "taux d'étudiants" et "motorisation" pour effectuer la deuxième régression.

## 2ème régression

Statistiques de la régression								
Coefficient d	0,969451772							
Coefficient d	0,939816739							
Coefficient d	0,931241987							
Erreur-type	1557,321181							
Observations	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	MS	F	Valeur critique de F			
Régression	3	795603572,9	265201191	109,350076	5,60783E-13			
Résidus	21	50930234,47	2425249,261					
Total	24	846533807,4						
	Coefficients	Erreur-type	Statistique t	Probabilité pour seuil de pour seuil de pour seuil de pour seuil de confiance = 95,0%				
Constante	-10712,0851	2984,737217	-3,58889404	0,001728402	-16919,2899	-4504,83026	-16919,2899	-4504,83026
Variable X 1	0,125744592	0,012267178	10,2504901	1,25404E-09	0,100233598	0,151255586	0,100233598	0,151255586
Variable X 2	117540,7226	13858,1849	8,48168237	3,18525E-08	88721,04953	146360,3957	88721,04953	146360,3957
Variable X 3	4701,245995	3622,941459	1,297632338	0,208487522	-2833,07319	12235,56518	-2833,07319	12235,56518

Le  $R^2$  est toujours satisfaisant (0.9398) ainsi que la valeur critique de F (5.6078E-13).

Cependant la probabilité t de la variable "motorisation" est supérieure à 5% : cette variable n'est pas significative.

Nous gardons donc les variables "population totale" et "taux d'étudiant" pour la régression suivante.

## 3ème régression

Statistiques de la régression								
Coefficient d	0,966960521							
Coefficient d	0,935013619							
Coefficient d	0,929104708							
Erreur-type	1581,339905							
Observation:	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	MS	F	Valeur critique de F			
Régression	2	791519817,7	395759908,8	158,2637079	8,73207E-14			
Résidus	22	55013989,68	2500635,894					
Total	24	846533807,4						
	Coefficients	Erreur-type	Statistique t	Probabilité pour seuil de pour seuil de pour seuil de pour seuil de confiance = 95,0%				
Constante	-6973,51206	792,0139405	-8,80478449	1,16003E-08	-8816,04843	-5330,97588	-8816,04843	-5330,97588
Variable X 1	0,119082099	0,011313923	10,52533555	4,71566E-10	0,095623459	0,142548739	0,095623459	0,142548739
Variable X 2	112533,1932	13513,33905	8,326331499	3,02031E-08	84504,09569	140562,2907	84504,09569	140562,2907

Le  $R^2$  est toujours satisfaisant (0.9350) ainsi que la valeur critique de F (8.7320E-14).

Les valeurs des probabilités t sont bons, ainsi que les valeurs seuils inférieures et supérieures (pas de changement de signe). Le signe des coefficients sont aussi logiques (plus la population est grande et plus le taux d'étudiants est grand, plus il y a de déplacements en émission pour le motif étudiant).

Nous pouvons maintenant forcer la constante à 0 (ce qui est logique car si la population est nulle ou si le nombre d'étudiants est nul, il n'y aura pas de déplacement en émission pour le motif étudiant).

Par ailleurs, il faut diviser le nombre de déplacements d'émission par la population totale pour avoir une valeur des coefficients cohérentes.

#### 4ème régression

Statistiques de la régression									
Coefficient d	0,9875918								
Coefficient d	0,975337564								
Coefficient d	0,930787023								
Erreur-type	0,017912918								
Observations	25								
ANALYSE DE VARIANCE									
	Degré de liberté	Somme des carrés	MS	F	pour critère de P				
Régression	2	0,291863304	0,145931652	454,796186	1,27399E-18				
Résidus	23	0,007380071	0,000320873						
Total	25	0,299243375							
Coefficients									
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de confiance = 95,0%				
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable X 1	-1,7672E-07	1,23267E-07	-1,43363896	0,165130938	-4,3172E-07	7,82771E-08	-4,3172E-07	7,82771E-08	
Variable X 2	1,86475769	0,113872624	16,37582086	3,589E-14	1,629194221	2,100321159	1,629194221	2,100321159	

Le R<sup>2</sup> est bon, ainsi que valeur seuil de F.

Cependant le signe du coefficient de la variable "population totale" n'est pas logique : en effet, plus la population est grande, plus le nombre de déplacement en émission doit être grand.

La régression finale comporte donc une unique variable : "le taux d'étudiant"

#### Régression finale :

Statistiques de la régression									
Coefficient d	0,986475385								
Coefficient d	0,973133685								
Coefficient d	0,931467018								
Erreur-type	0,018302512								
Observations	25								
ANALYSE DE VARIANCE									
	Degré de liberté	Somme des carrés	MS	F	pour critère de P				
Régression	1	0,291203808	0,291203808	869,311933	8,92272E-20				
Résidus	24	0,008039567	0,000334982						
Total	25	0,299243375							
Coefficients									
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de confiance = 95,0%				
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable X 1	1,72360815	0,058458911	29,48409627	2,30814E-20	1,602954889	1,844261411	1,602954889	1,844261411	

Le R<sup>2</sup> est excellent (0.9731), ainsi que le F de Fisher (8.922E-20).

La probabilité t de la variable est très inférieure à 5% et l'on trouve un coefficient de 1.72. Cela signifie qu'un étudiant réalise en moyenne 1.72 déplacements par jour pour le motif étudiant en émission. Cela semble cohérent, en comptant un aller-retour par jour par étudiant, moins les jours où les étudiants n'ont pas cours.

## Attraction :

En attraction, nous allons réaliser le même type de raisonnement pour arriver à la meilleure régression.

### 1ère régression

La première régression utilise les même 8 variables qu'en émission.

Statistiques de la régression								
Coefficient	0,9608436							
Coefficient	0,9232204							
Coefficient	0,8848305							
Erreur-type	3064,5317							
Observation	25							
ANALYSE DE VARIANCE								
	Degré de liberté	mmme des carvenne des cai	F	eur critique de F				
Régression	8	1,807E+09	225848648	24,04857	1,612E-07			
Résidus	16	150261675	9391354,7					
Total	24	1,957E+09						
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de	pour seuil de	pour seuil de	pour seuil de
Constante	-15185,606	12284,977	-1,236112	0,2342572	-41228,593	10857,38	-41228,593	10857,38
Variable X1	0,1167359	0,0353274	3,3043973	0,0044776	0,0418451	0,1916267	0,0418451	0,1916267
Variable X2	34602,37	41808,927	0,827631	0,4200529	54028,595	123233,33	-54028,595	123233,33
Variable X3	-46466,388	32215,97	-1,4423402	0,168496	114761,19	21828,416	-114761,19	21828,416
Variable X4	82554,461	40586,747	2,034025	0,0588754	3485,5986	168594,52	-3485,5986	168594,52
Variable X5	12691,015	25884,614	0,4902911	0,6305828	-42181,914	67563,945	-42181,914	67563,945
Variable X6	-0,0024494	0,3050095	-0,0080304	0,993692	-0,6490406	0,6441419	-0,6490406	0,6441419
Variable X7	0,5106597	0,0882289	5,7878935	2,774E-05	0,3236227	0,6976966	0,3236227	0,6976966
Variable X8	8423,8307	9996,3492	0,8426907	0,4118211	-12767,483	29615,144	-12767,483	29615,144

Le  $R^2$  est bon, ainsi que le coefficient F.

En enlevant les variables dont la probabilités t sont supérieures à 5%, il ne reste que les variables "population totale" et "nombre de places d'étudiants".

## 2ème régression

Statistiques de la régression								
Coefficient	0,9351107							
Coefficient	0,874432							
Coefficient	0,8254943							
Erreur-type	3800,5482							
Observation	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	Erreur-type	F	Statistique t	Probabilité	pour seuil de	pour seuil de
Régression	2	2,313E+09	1,157E+09	80,083857				
Résidus	23	332215827	14444166					
Total	25	2,646E+09						
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de	pour seuil de	pour seuil de	pour seuil de
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable X :	0,0785164	0,0166299	4,7213879	9,322E-05	0,0441147	0,112918	0,0441147	0,112918
Variable X :	0,6059961	0,0949142	6,3846708	1,627E-06	0,4096511	0,8023411	0,4096511	0,8023411

## Régression finale

On peut se demander si en ne gardant que la variable "nombre de place étudiants", la régression sera meilleure.

Nous avons réalisé cette régression pour s'en assurer :

Statistiques de la régression								
Coefficient	0,8676013							
Coefficient	0,7527321							
Coefficient	0,7110654							
Erreur-type	5220,9435							
Observation	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	Erreur-type	F	Statistique t	Probabilité	pour seuil de	pour seuil de
Régression	1	1,992E+09	1,992E+09	73,060701				
Résidus	24	654198016	27258251					
Total	25	2,646E+09						
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de	pour seuil de	pour seuil de	pour seuil de
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable :	0,8806437	0,1090287	8,5475553	9,587E-09	0,6580028	1,0932845	0,6580028	1,0932845

En ne gardant que la variable "nombre de place étudiants", on trouve un coefficient  $R^2$  corrigé plus faible qu'avec les variables "nombre de places étudiants" et "population totale" (0.7110 contre 0.8254).

Cela signifie que la régression précédente est plus performante.

Cependant cette régression apporte plus d'information que la précédente : le coefficient apporte plus d'information, c'est-à-dire il y a 0.88 déplacement par jour par étudiant en attraction pour le motif étudiant.

# Comparaison avec 1985

## Emission

Nous avons repris la meilleure régression de 1995 et nous l'avons appliqué aux données de 1985.

Statistiques de la régression								
Coefficient d	0,962602459							
Coefficient d	0,926603495							
Coefficient d	0,884936828							
Erreur-type	0,018031827							
Observation:	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	MS	F	valeur critique de F			
Régression	1	0,098516565	0,098516565	302,9910446	9,74855E-15			
Résidus	24	0,007803523	0,000325147					
Total	25	0,106320088						
Coefficients								
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de	pour seuil de	pour seuil de	pour seuil de confiance = 95,0%
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable X 1	1,517560404	0,087182861	17,40663795	4,07996E-15	1,337623914	1,697497073	1,337623914	1,697497073

On trouve un  $R^2$  de 0.9266 et une valeur critique bonne de 9.748E-15 avec une bonne probabilité inférieure à 5%.

Le coefficient est de 1.52, ce qui est à peu près similaire au coefficient trouvé en 1995 de 1.72. Cela signifie qu'entre 1985 et 1995, le nombre de déplacements de par jour a légèrement augmenté.

## Attraction

Statistiques de la régression								
Coefficient d	0,9457693							
Coefficient d	0,894479568							
Coefficient d	0,852812901							
Erreur-type	2176,429675							
Observation:	25							
ANALYSE DE VARIANCE								
	Degré de liberté	Somme des carrés	MS	F	valeur critique de F			
Régression	1	969883412	969883412	205,4441091	6,53867E-13			
Résidus	24	113684307,1	4736846,129					
Total	25	1077367719						
Coefficients								
	Coefficients	Erreur-type	Statistique t	Probabilité	pour seuil de	pour seuil de	pour seuil de	pour seuil de confiance = 95,0%
Constante	0	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A	#N/A
Variable X 1	1,04302865	0,073126314	14,2633833	3,23307E-13	0,892103356	1,193953944	0,892103356	1,193953944

On trouve un  $R^2$  bon de 0.8944 et une bonne valeur critique de F.

Le coefficient est de 1.04, ce qui est légèrement plus important qu'en 1995. Cela signifie que le nombre de déplacement à diminué entre 1985 et 1995 pour le motif étudiant.