

KOUROSH KAZEMI, FLORA MULON, JENNY RAHARIMANANA

LAS VEGAS

COMMENTAIRES EN LIGNE DE
21 HOTELS DE LAS VEGAS



TABLE DE DONNÉES

Las Vegas Strip Data Set :
commentaires TripAdvisor posté en 2015 concernant
21 hôtels de Las Vegas (24 commentaires par hôtel)

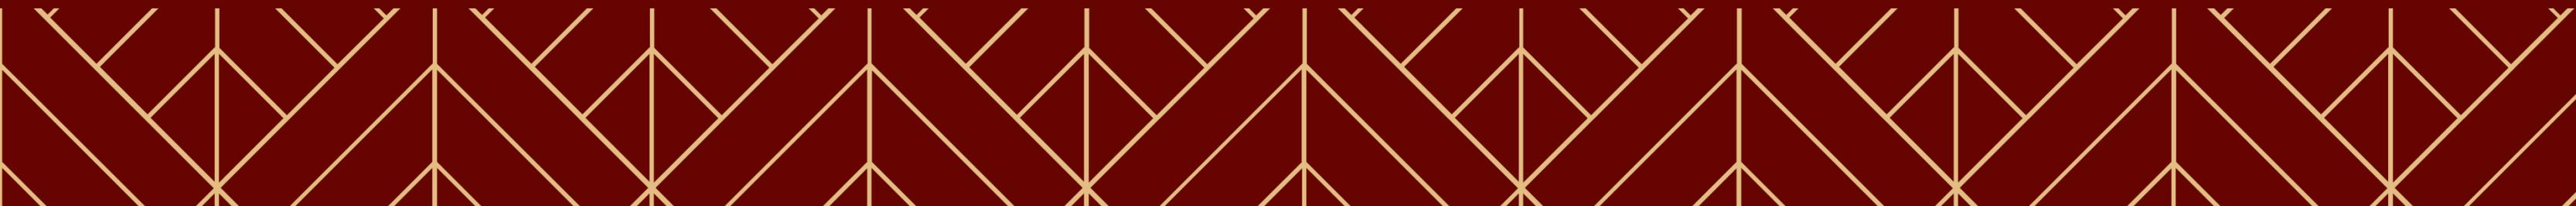


TABLE DE DONNÉES

20 VARIABLES



HOTEL

Nom
Etoile(s)
Revue
Chambres
Piscine
Salle de sport
Tennis
Spa
Casino
Internet




TABLE DE DONNÉES

20 VARIABLES



HOTEL

Nom
Etoile(s)
Revue
Chambres
Piscine
Salle de sport
Tennis
Spa
Casino
Internet

CLIENT

Pays
Nombre de
revues
Type
Saison du
séjour
Continent
Nombre
d'année de
membre




TABLE DE DONNÉES

20 VARIABLES



HOTEL

Nom
Etoile(s)
Revue
Chambres
Piscine
Salle de sport
Tennis
Spa
Casino
Internet

REVUE

Nombre de
votes utiles
Jour et mois
de publication

CLIENT

Pays
Nombre de
revues
Type
Saison du
séjour
Continent
Nombre
d'année de
membre



TABLE DE DONNÉES

20 VARIABLES



HOTEL

Nom
Etoile(s)
Revue
Chambres
Piscine
Salle de sport
Tennis
Spa
Casino
Internet

REVUE

Nombre de
votes utiles
Jour et mois
de publication

RÉPONSE

Note de 1 à 5
attribuées par
l'utilisateur

CLIENT

Pays
Nombre de
revues
Type
Saison du
séjour
Continent
Nombre
d'année de
membre

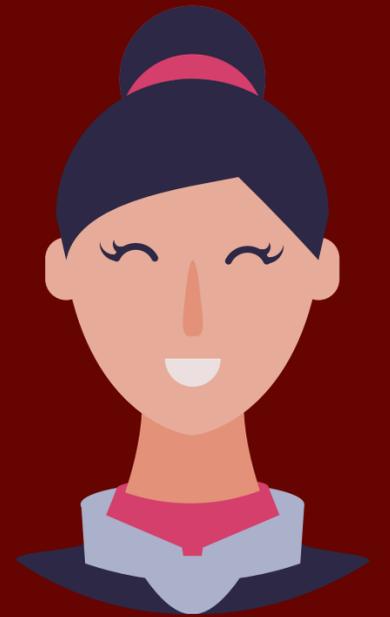


TABLE DE DONNÉES

20 VARIABLES



Modèle Logit Ordonné



RÉPONSE

Note de 1 à 5
attribuées par
l'utilisateur

TABLE DE DONNÉES

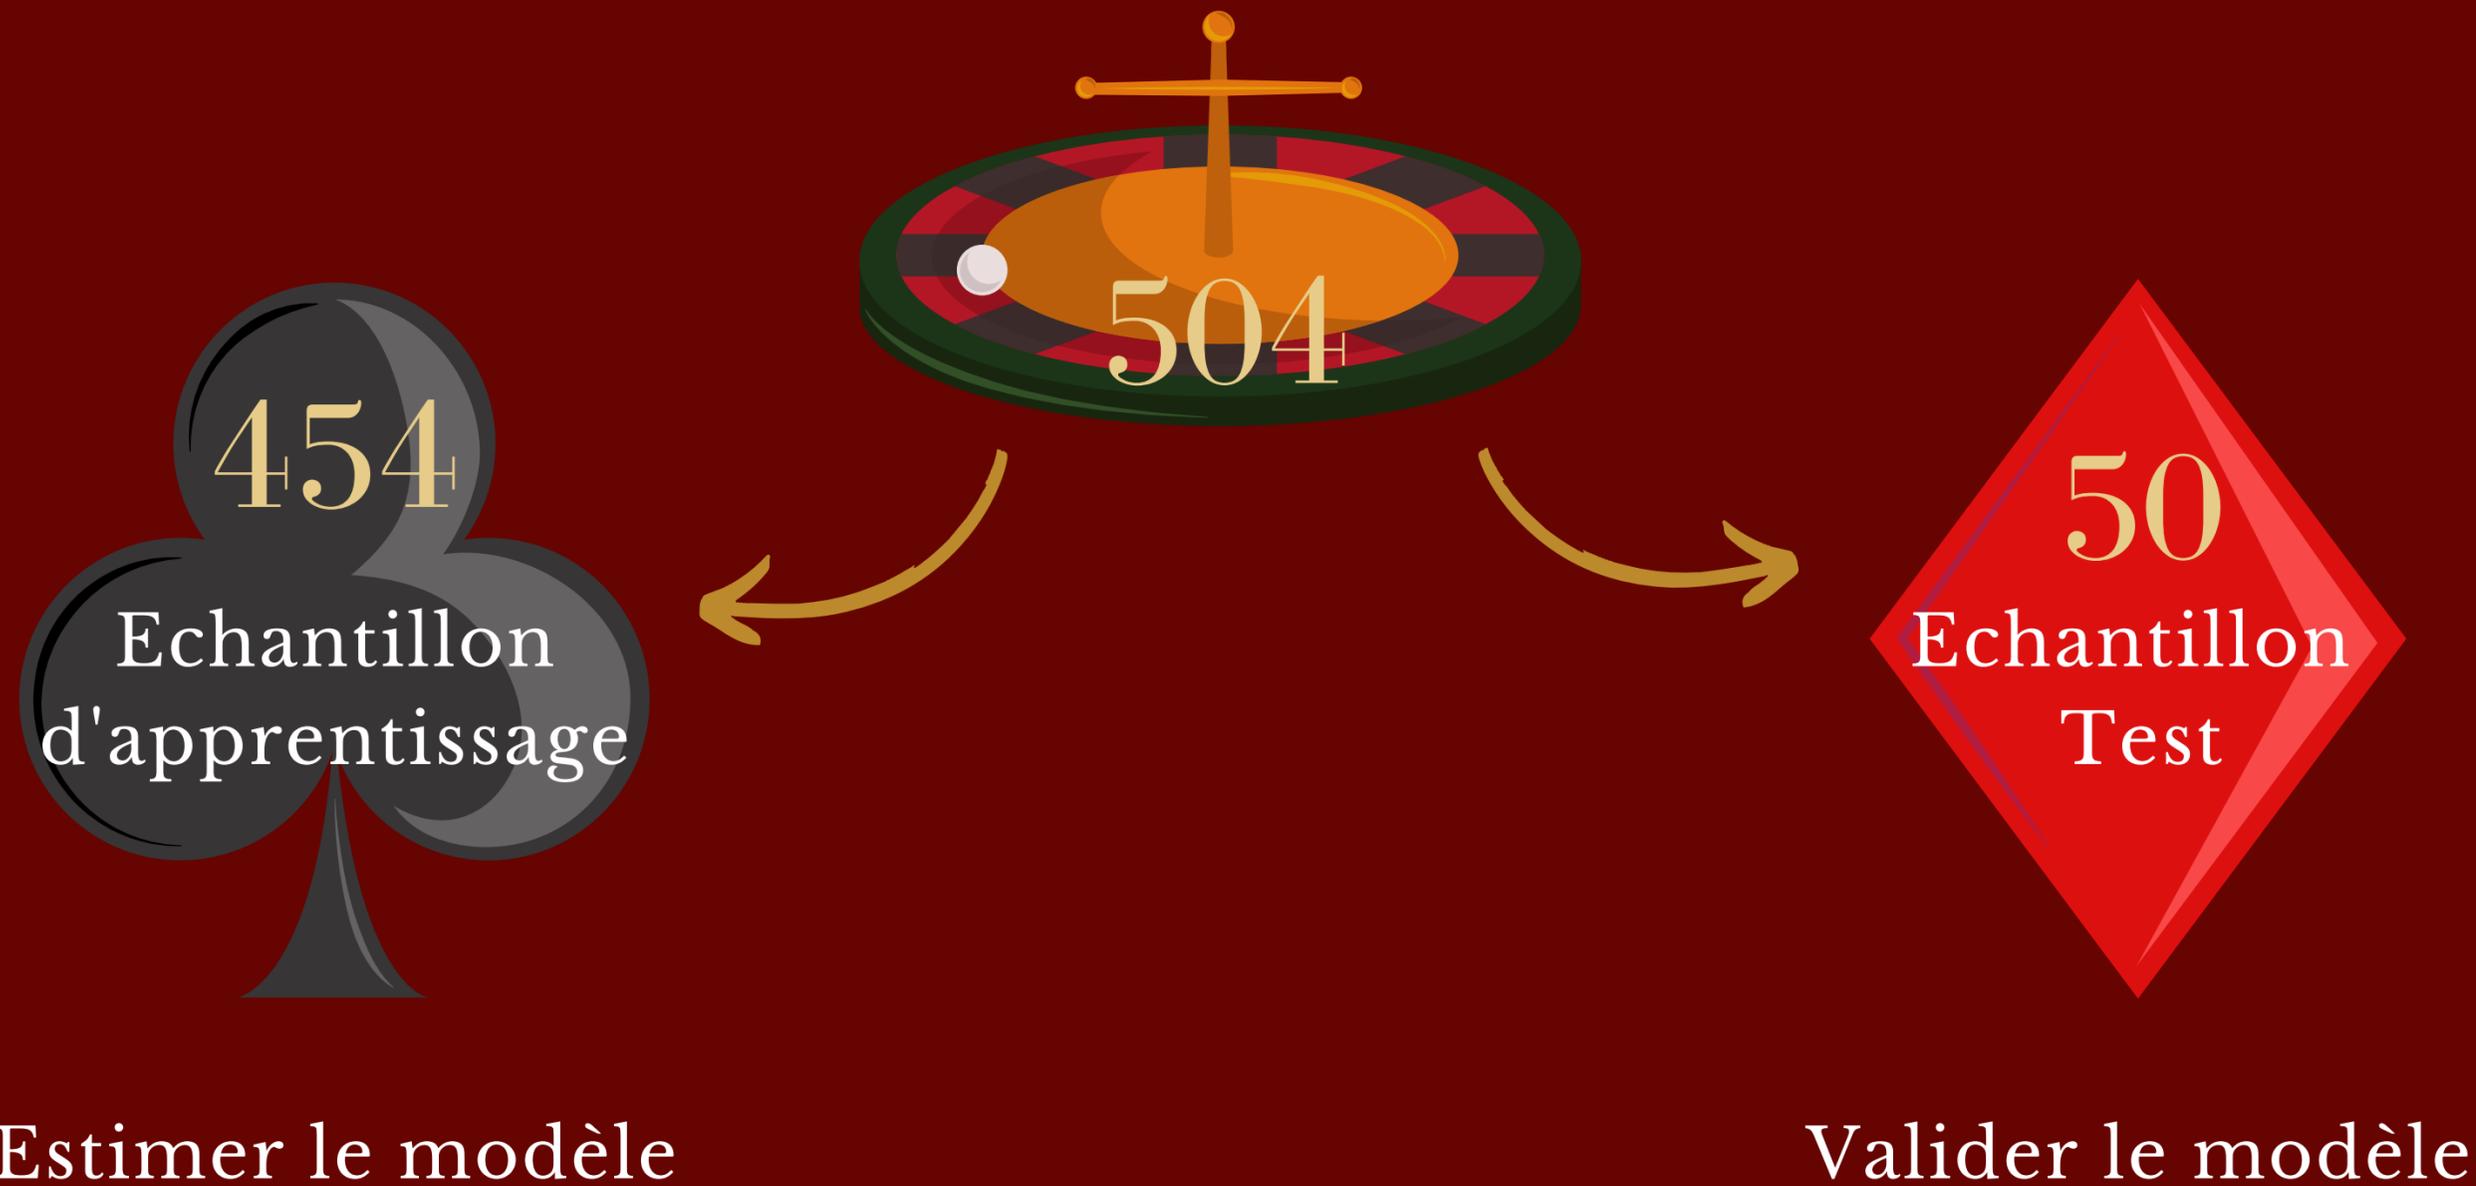


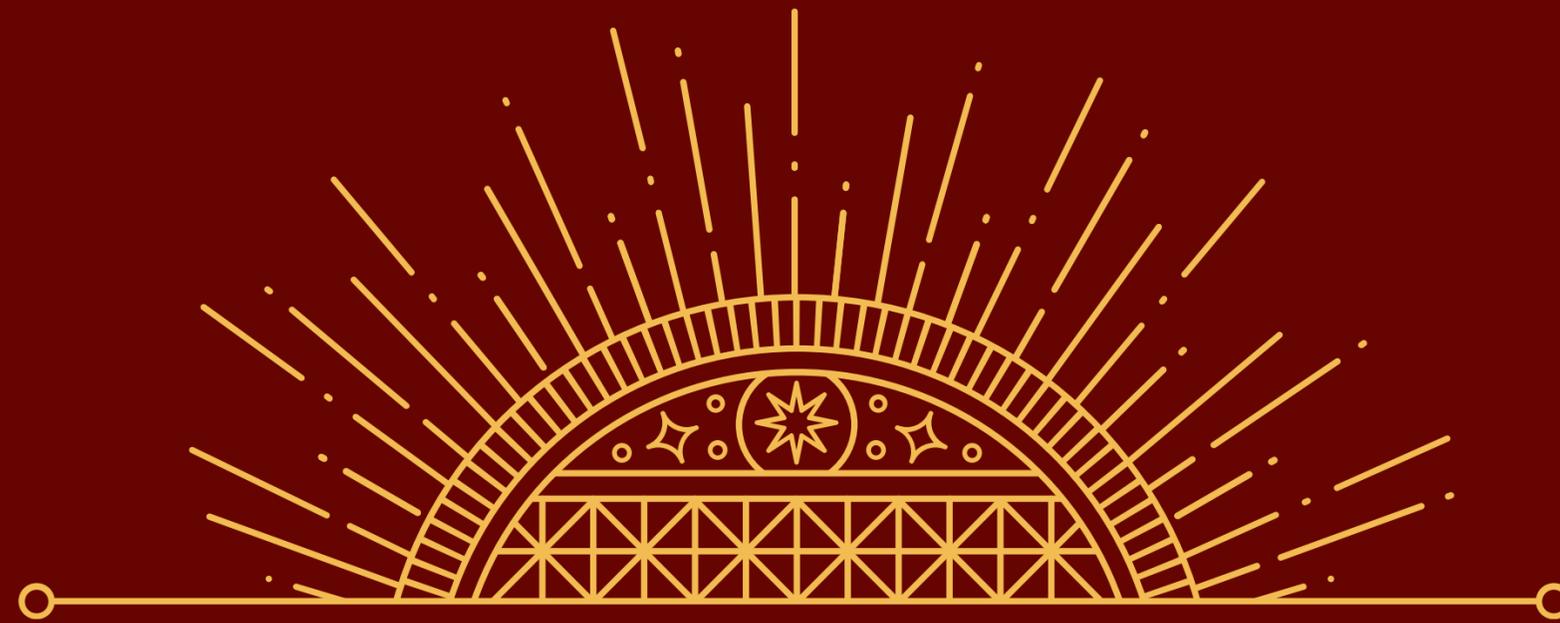
TABLE DE DONNÉES



Estimer le modèle

TABLE DE DONNÉES





COMMENT EXPLIQUER LE SCORE D'UN HOTEL ?



PLAN :



Construction du modèle



Interprétation du modèle



Prédiction sur l'ensemble test

A

VARIABLES



Suppression de certaines variables non pertinentes comme :

Jour et mois de
publication du
commentaire

Nombre de votes
utiles sur le
commentaire

Nombre de chambres
et d'étoiles de l'hôtel

Pays de
l'utilisateur



A CONSTRUCTION DU MODÈLE



Résultats de la sélection des variables significatives
avec les 3 méthodes :

STEPWISE

FORWARD

BACKWARD

procédure PROC LOGISTIC de SAS



A CONSTRUCTION DU MODÈLE



Résultats de la sélection des variables significatives
avec les 3 méthodes :

STEPWISE

FORWARD

BACKWARD

Hotelname
Traveler
Nbreviews
Continent



procédure PROC LOGISTIC de SAS



A CONSTRUCTION DU MODÈLE



Résultats de la sélection des variables significatives
avec les 3 méthodes :

STEPWISE

Hotelname
Traveler
Nbreviews
Continent

FORWARD

Hotelname
Traveler
Nbreviews
Continent

BACKWARD



procédure PROC LOGISTIC de SAS



A CONSTRUCTION DU MODÈLE



Résultats de la sélection des variables significatives
avec les 3 méthodes :

STEPWISE

Hotelname
Traveler
Nbreviews
Continent

FORWARD

Hotelname
Traveler
Nbreviews
Continent

BACKWARD

Nbreviews
Traveler
Pool
Gym
Casino
Internet
Hotelname
Continent



A

MEILLEUR MODÈLE



Notre modèle est donc composé de 4 variables :
Hotelname, Traveler, Nbreviews et Continent.

$$\begin{array}{l} \text{Score} = \\ \text{constante} \\ \text{Hotelname} \\ \text{Traveler} \\ \text{Nbreviews} \\ \text{Continent} \end{array}$$



V

A

MEILLEUR MODÈLE



Notre modèle est donc composé de 4 variables :
Hotelname, Traveler, Nbreviews et Continent.

Le modèle est globalement significatif

Quelques statistiques importantes sur le modèle :

D de Somers : 0.406

Gamma : 0.408

Tau-a : 0.271

c : 0.703

$$\begin{aligned} \text{Score} = & \\ & \text{constante} \\ & \text{Hotelname} \\ & \text{Traveler} \\ & \text{Nbreviews} \\ & \text{Continent} \end{aligned}$$



V

2

INTERPRÉTATION DU MODÈLE



Les modalités des variables **qualitatives** mises en référence sont les suivantes :

- la variable **HotelName**, la référence est l'hôtel **Wynn Las Vegas**,
- la variable **Traveler** (type de voyage), la référence est la modalité **Solo**
- la variable **Continent**, la référence est la modalité **South America**

R^2 de McFadden = 0.9164



2

INTERPRÉTATION

Des signes des variables



Hotel Excalibur & Casino = 2.4482 (p-value <0.0001)

Un client ayant résidé à l'hôtel Excalibur & Casino est généralement plus satisfait qu'un client ayant résidé à l'hôtel Wynn Las Vegas.



2

2

INTERPRÉTATION



Définition des Cotes :

MODÈLE DICHOTOMIQUE SIMPLE :

$$C_i = P(i=1) / 1 - P(i=1)$$

= probabilité de connaître l'évènement sur la probabilité de ne pas le connaître



2

INTERPRÉTATION



Définition des Cotes :

MODÈLE DICHOTOMIQUE SIMPLE :

$$C_i = P(i=1) / 1-P(i=1)$$

= probabilité de connaître l'évènement sur la probabilité de ne pas le connaître

MODÈLE MULTINOMIAL ORDONNÉ :

$$C_{ji} = P(j \leq m) / P(j > m)$$

= probabilité que la variable y soit inférieure à une certaine modalité sur la probabilité que la variable y soit strictement supérieure à cette modalité



2

INTERPRÉTATION



Définition des Cotes :

MODÈLE DICHOTOMIQUE SIMPLE :

$$C_i = P(i=1) / 1-P(i=1)$$

= probabilité de connaître l'évènement sur la probabilité de ne pas le connaître

MODÈLE MULTINOMIAL ORDONNÉ :

$$C_{ji} = P(j \leq m) / P(j > m)$$

= probabilité que la variable y soit inférieure à une certaine modalité sur la probabilité que la variable y soit strictement supérieure à cette modalité

Le rapport des cotes :

rapport entre la cote d'une variable sur la cote d'une autre variable



2 INTERPRÉTATION

Des signes des variables



$RC(\text{Hotelname Caesars Palace vs Wynn Las Vegas}) = 3.846$

et significatif (car l'intervalle de confiance est compris entre 1.073, et 13.784)

Un client ayant résidé à l'hôtel Caesars Palace a plus tendance à attribué une note supérieure à 1 qu'un individu ayant résidé au Wynn Las Vegas.



3

PRÉDICTION

Sous forme de variable dichotomique

Recodage de la variable Score

Obs.	Nbreviews	Score	Traveler	Hotelname	Continent
1	11	5	Friends	Circus Circus Hotel & Casino Las Vegas	North America
2	119	3	Business	Circus Circus Hotel & Casino Las Vegas	North America
3	36	5	Families	Circus Circus Hotel & Casino Las Vegas	North America
4	14	4	Friends	Circus Circus Hotel & Casino Las Vegas	Europe
5	5	4	Solo	Circus Circus Hotel & Casino Las Vegas	North America
6	31	3	Couples	Circus Circus Hotel & Casino Las Vegas	North America
7	45	4	Couples	Circus Circus Hotel & Casino Las Vegas	Europe
8	2	4	Families	Circus Circus Hotel & Casino Las Vegas	North America
9	24	4	Friends	Circus Circus Hotel & Casino Las Vegas	Asia
10	12	3	Families	Circus Circus Hotel & Casino Las Vegas	North America



3

PRÉDICTION

Sous forme de variable dichotomique

Recodage de la variable Score

Obs.	Nbreviews	Score	Traveler	Hotelname	Continent
1	11	1	Friends	Circus Circus Hotel & Casino Las Vegas	North America
2	119	0	Business	Circus Circus Hotel & Casino Las Vegas	North America
3	36	1	Families	Circus Circus Hotel & Casino Las Vegas	North America
4	14	1	Friends	Circus Circus Hotel & Casino Las Vegas	Europe
5	5	1	Solo	Circus Circus Hotel & Casino Las Vegas	North America
6	31	0	Couples	Circus Circus Hotel & Casino Las Vegas	North America
7	45	1	Couples	Circus Circus Hotel & Casino Las Vegas	Europe
8	2	1	Families	Circus Circus Hotel & Casino Las Vegas	North America
9	24	1	Friends	Circus Circus Hotel & Casino Las Vegas	Asia
10	12	0	Families	Circus Circus Hotel & Casino Las Vegas	North America



Caractéristiques des deux échantillons :

Echantillon d'apprentissage

Moyenne : 0.4529

Ecart-type : 0.4984

Echantillon test

Moyenne : 0.44

Ecart-type : 0.4988



3

PRÉDICTION

Caractéristiques des deux échantillons :

Echantillon d'apprentissage

Moyenne : 0.4529

Ecart-type : 0.4984

Echantillon test

Moyenne : 0.44

Ecart-type : 0.4988

Test ANOVA : test d'égalité des moyennes entre l'échantillon d'Apprentissage et l'échantillon Test :

p-value du test = 0.9105

Conclusion : moyennes identiques entre les deux échantillons



3

PRÉDICTION

Caractéristiques des deux échantillons :



Echantillon d'apprentissage

Moyenne : 0.4529

Ecart-type : 0.4984

Echantillon test

Moyenne : 0.44

Ecart-type : 0.4988

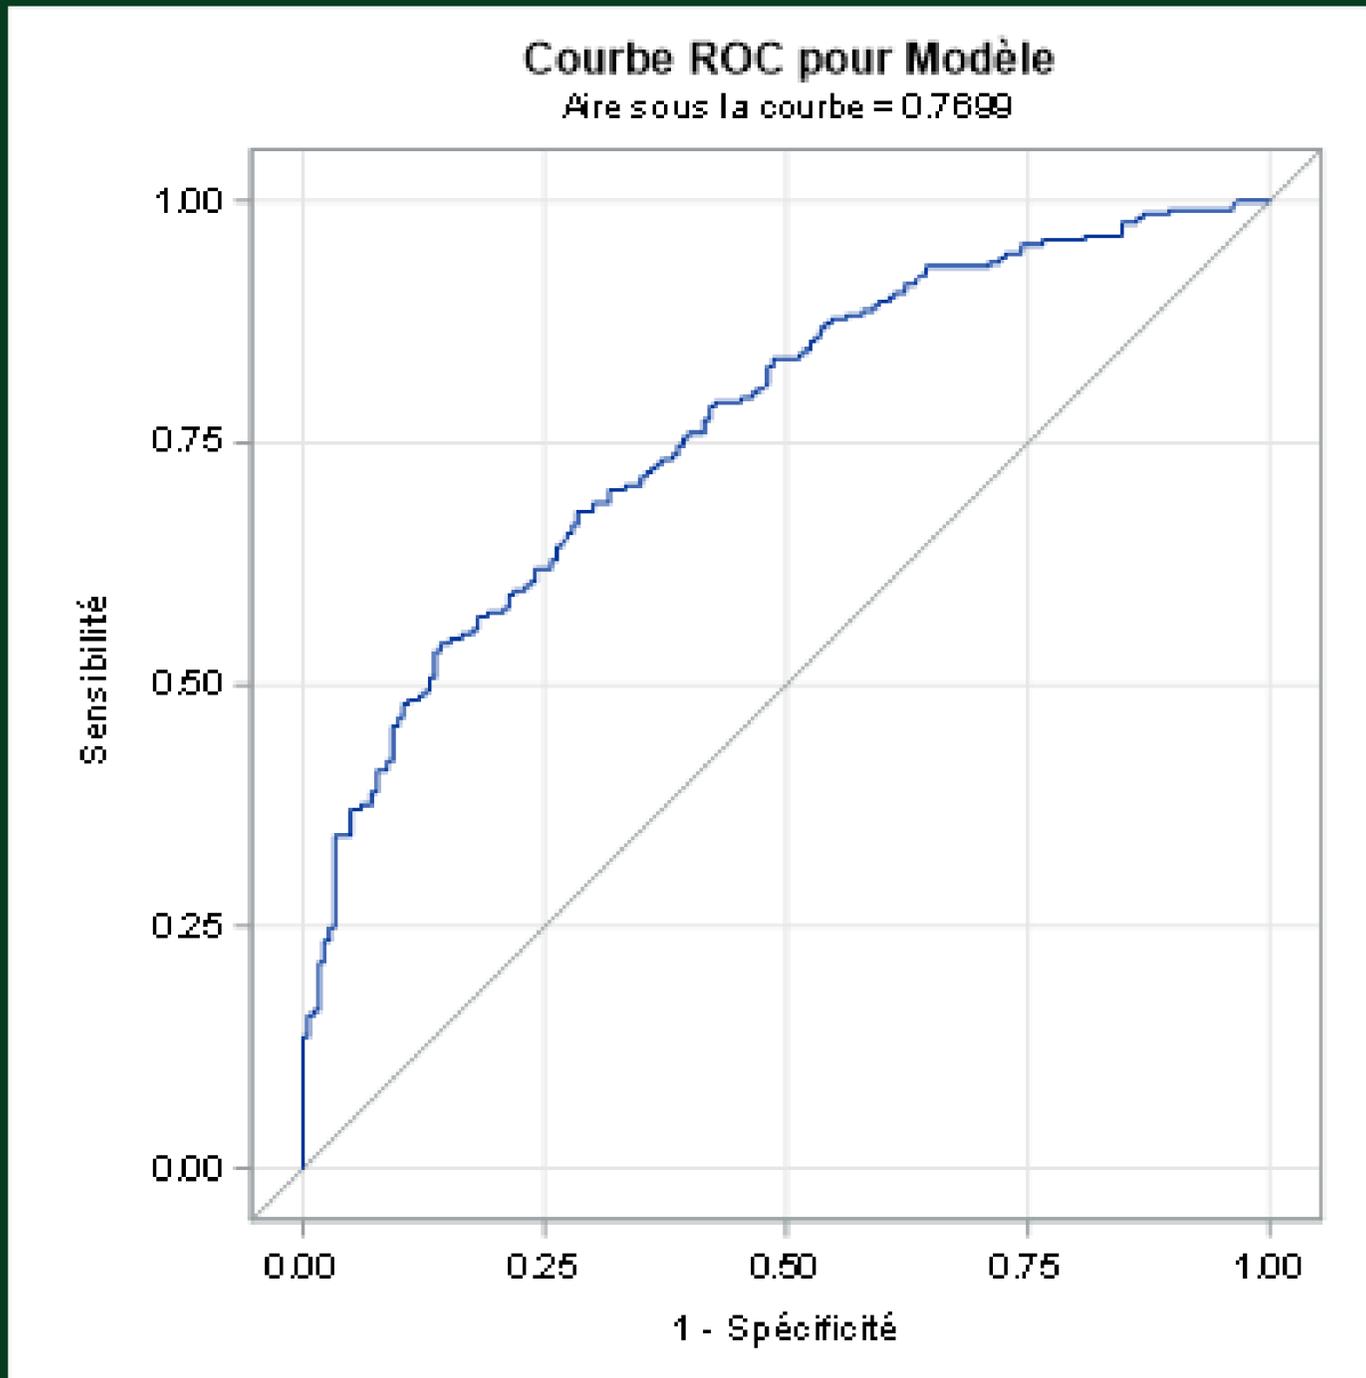
Test de Levene : test d'équivalence des variances entre l'échantillons d'Apprentissage et l'échantillon Test

p-value du test : 0.8939

Conclusion : variances identiques entre les deux échantillons



De la variable Score sur l'ensemble d'apprentissage



Association des probabilités prédites et des réponses observées			
Pourcentage concordant	77.0	D de Somers	0.540
Pourcentage discordant	23.0	Gamma	0.540
Pourcentage lié	0.0	Tau-a	0.268
Paires	40443	c	0.770

L'AUC est égale à la statistique c.

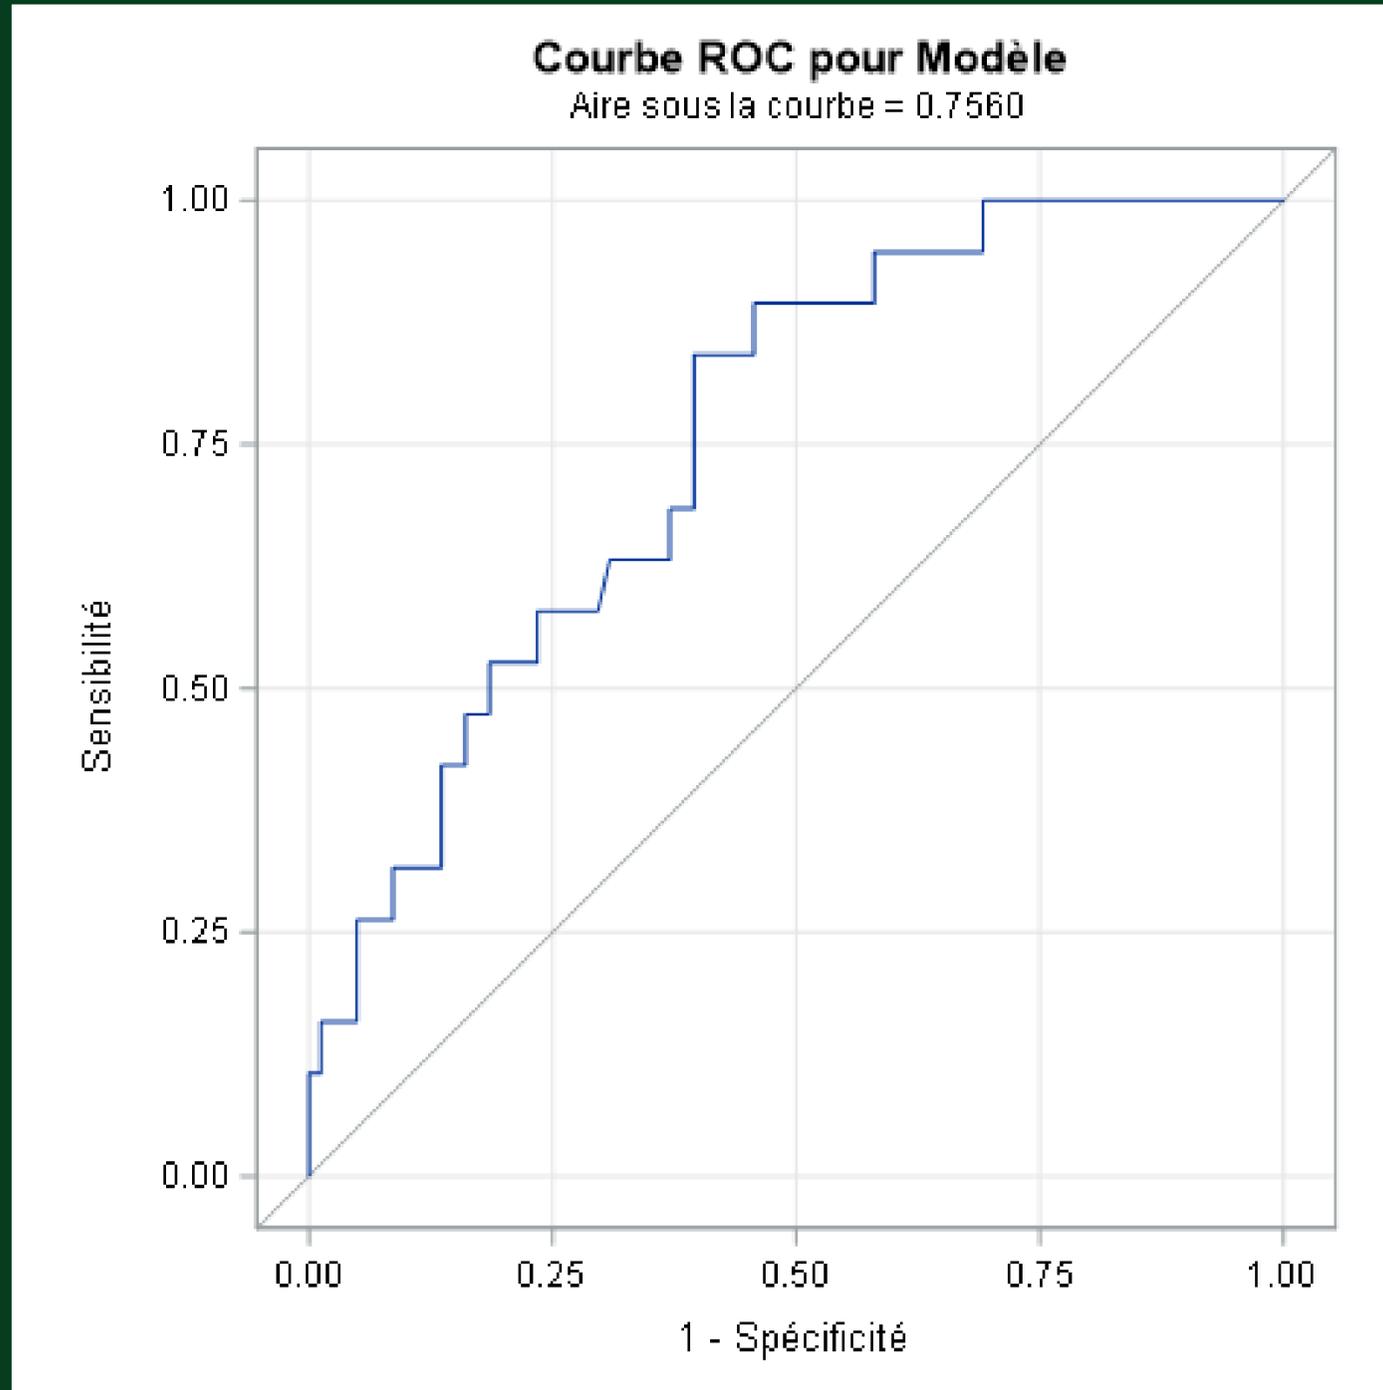


3



PRÉDICTION

De la variable Score sur l'ensemble TEST



Association des probabilités prédites et des réponses observées			
Pourcentage concordant	75.1	D de Somers	0.502
Pourcentage discordant	24.8	Gamma	0.503
Pourcentage lié	0.1	Tau-a	0.250
Paires	2464	c	0.751

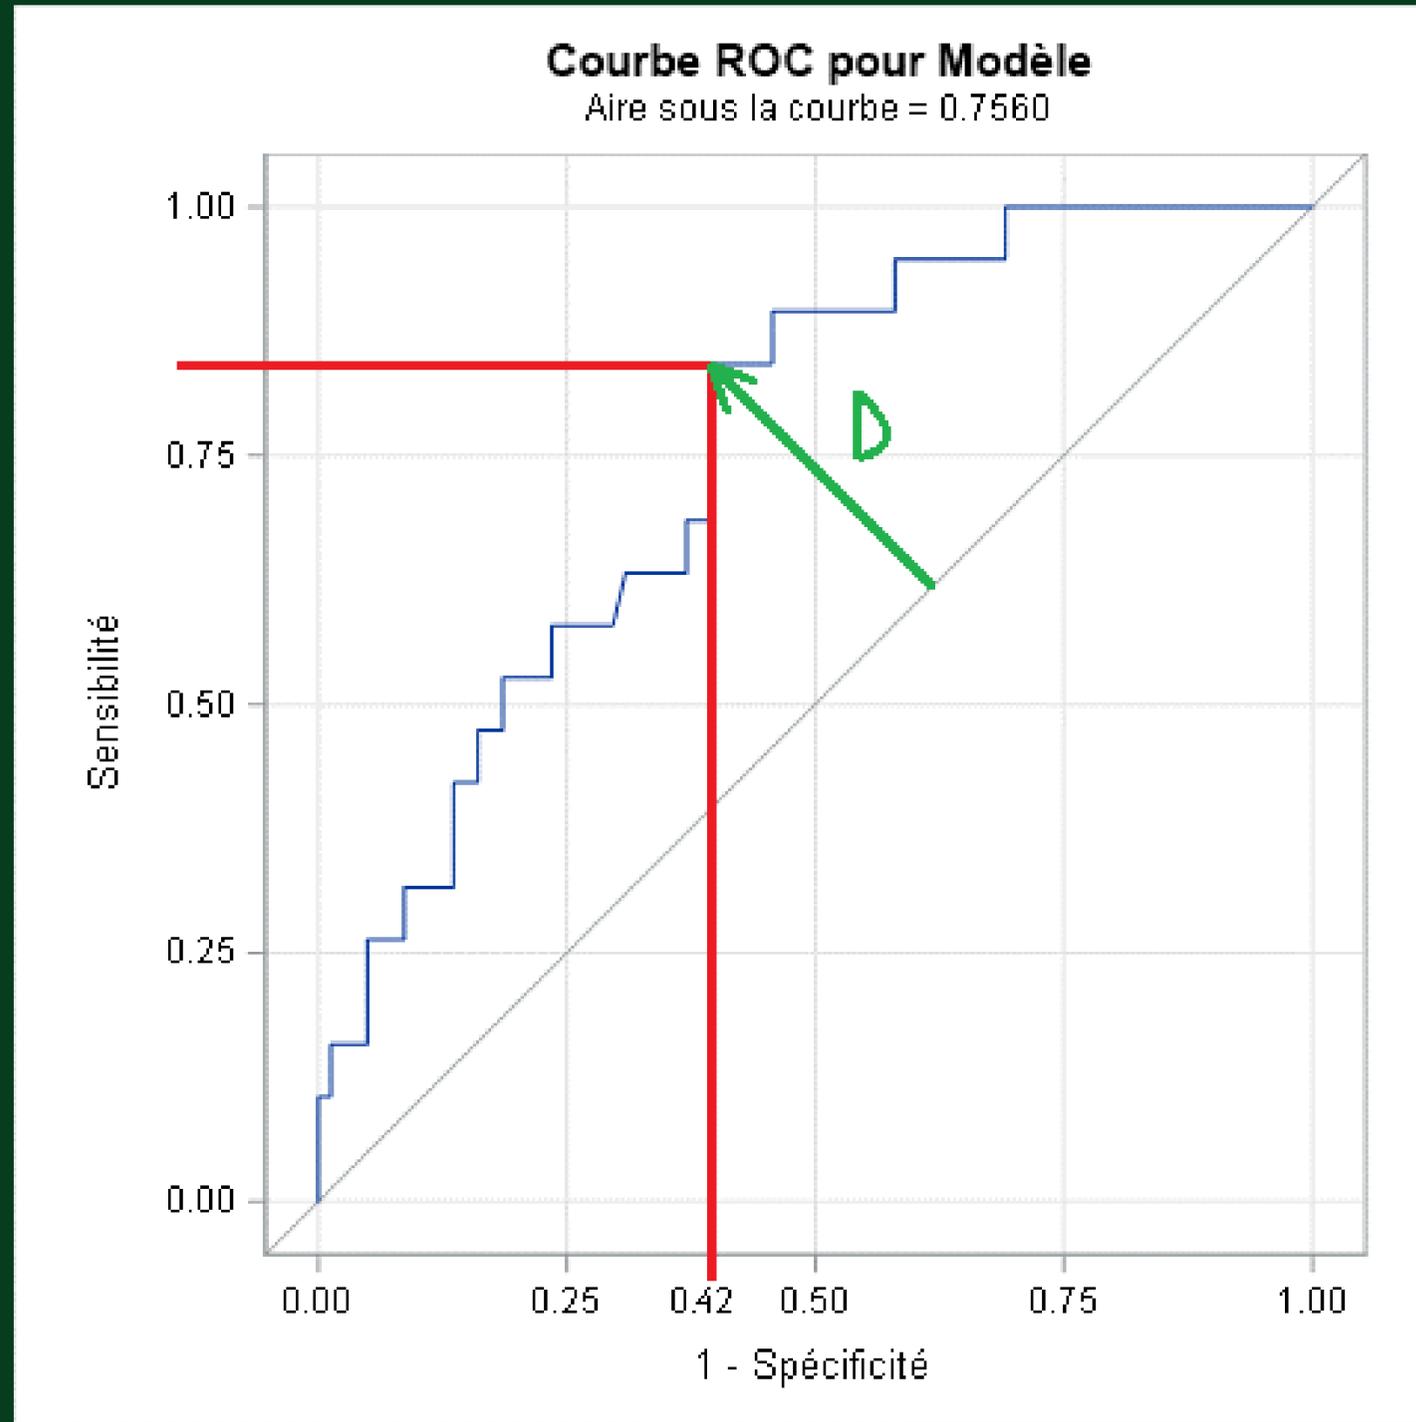
La différence entre les deux courbes ROC est assez **faible**.





PRÉDICTION

Déduction du Cutoff optimal du modèle



Maximisation de la distance euclidienne entre la droite à 45° et la courbe de la ROC

Obs.	_PROB_	D
1	0.21641	0.42545

Cutoff optimal = 0.42



3

PRÉDICTION

Taux de bonnes et mauvaises prédictions
avec un CUTOFF=0.42



Table de Score par PREDICTION			
Score	PREDICTION		
Fréquence Pourcentage	0	1	Total
0	37 37.00	20 20.00	57 57.00
1	0 0.00	43 43.00	43 43.00
Total	37 37.00	63 63.00	100 100.00

Sensibilité	Spécificité
1	0.6491
Faux négatifs	Faux positifs
0	0.3175



3

PRÉDICTION

Taux de bonnes et mauvaises prédictions
avec un CUTOFF=0.42



Sensibilité = Proportion d'individu ayant connu l'événement et ayant été identifié comme tel par le modèle de prédiction.

Spécificité = Proportion d'individu n'ayant pas connu l'événement et ayant été identifié comme tel par le modèle de prédiction.

Sensibilité	Spécificité
1	0.6491
Faux négatifs	Faux positifs
0	0.3175



3

PRÉDICTION

Taux de bonnes et mauvaises prédictions
avec un CUTOFF=0.42



Sensibilité = Proportion d'individu ayant connu l'événement et ayant été identifié comme tel par le modèle de prédiction.

Spécificité = Proportion d'individu n'ayant pas connu l'événement et ayant été identifié comme tel par le modèle de prédiction.

Faux positifs = Proportion d'individu identifié à tort comme ayant connu l'événement

Faux négatifs = Proportion d'individu identifié à tort comme n'ayant pas connu l'événement

Sensibilité	Spécificité
1	0.6491
Faux négatifs	Faux positifs
0	0.3175



Taux de bonnes et mauvaises prédictions
avec un CUTOFF=0.42

Taux Mauvaises Classification	Taux Bonnes Classification
0.27970	0.72030

72% de bonnes classifications, ce qui nous permet de conclure que le modèle construit génère de bonnes prévisions.



CONCLUSION :

◆ Même si le coefficient de détermination de notre modèle n'est pas très élevé ($R^2 = 0,56$), nous avons réussi à construire un modèle explicatif du score attribué à 24 hotels de Las Vegas sur le site TripAdvisor.



CONCLUSION :

◆ Même si le coefficient de détermination de notre modèle n'est pas très élevé ($R^2 = 0,56$), nous avons réussi à construire un modèle explicatif du score attribué à 24 hôtels de Las Vegas sur le site TripAdvisor.

On peut donc expliquer une note élevée par le nom de l'hôtel, le profil et le continent du voyageur, ainsi que le nombre de revues de l'hôtel sur le site.



CONCLUSION :

Conseil pour obtenir de meilleures notes sur
TripAdvisor :

- améliorer les séjours des couples ou de ceux
qui voyagent entre amis
- attirer davantage les clients avec un profil
Business et familles

