République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Mohamed Khider, Biskra

Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie

Départementde Mathématiques

Mémoire présenté pour obtenir le diplôme de

Master en "**Mathematiques Appliquées**"

Option : Statistique

Par KHERFI Abdelhakim

Titre :

Titre du mémoire Estimation Paramétrique des Modéles de Régression Non Linéaire àl'aide des Algorithmes de Réseaux de Neurones en R

Devant le Jury :

Mr.	Cherfaoui Mouloud	Prof.	U. Biskra	Président
Mr.	Brahimi Brahim	Prof.	U. Biskra	Rapporteur
Mam.	Tour Madiha	M.C.B.	U. Biskra	Examinateur

Dédicace

Je dédie ce modeste travail à :

Mes chers parents qui ont mobilisé toutes leurs ressources pour mon éducation et mon instruction.

Ma famille bien-aimée (mes frères et sœurs) qui ont toujours été mon soutien et mon appui.

Mes honorables professeurs dont j'ai bénéficié du savoir précieux et des orientations éclairées.

Toutes les personnes qui ont contribué à la réalisation de ce travail.

Je prie Allah le Tout-Puissant d'agréer ce travail comme une œuvre sincère et de le rendre utile à Ses serviteurs.

Remerciements

Avant tout, je tiens à exprimer ma profonde gratitude envers **Allah** Tout-Puissant qui m'a accordé la force,la patience et la santé pour mener à bien ce modeste travail.

Tout d'abord, je tiens à remercier Allah de m'avoir accordé le courage,la patience et la santé pour accomplir ce modeste travail.

Je remercie sincèrement mon superviseur,**M. Brahimy Brahim**,pour ses précieux conseils,son encadrement et sa patience tout au long de ce projet.

Je suis également reconnaissant(e) envers les membres du jury :Le :**Pr.Cherfaoui Mouloud** et le **Mam.Tour Madiha** pour avoir accepté d'évaluer et d'examiner ce travail.

Je tiens à adresser mes sincères remerciements à ma famille qui m'a toujours soutenu et accompagné dans toutes mes activités."

Je n'oublie pas de remercier tous mes enseignants,qui ont contribué à ma formation au cours de ces cinq années.

Enfin,je tiens à adresser mes remerciements les plus sincères à tous ceux qui ont contribué,de près ou de loin,directement ou indirectement,à la réalisation de ce travail.

Notations et symbols

y_i	$\longrightarrow$	La i^{eme} observation de la variable aléatoire à expliquer$Y$.
x_i	$\longrightarrow$	La i^{eme} observation de la variable explicative$X$.
β_0 et β_1	$\longrightarrow$	Sont des constantes inconnues appelées paramétres du modéle.
ε_i	$\longrightarrow$	L'erreur (ou bruit) aléatoire du modéle.
$\overline{x}$	$\longrightarrow$	Les moyennes empiriques des x_i.
$\overline{y}$	$\longrightarrow$	Les moyennes empiriques des y_i.
S_x	$\longrightarrow$	Somme des carrés des écarts (variabilité) pour x.
S_y	$\longrightarrow$	Somme des carrés des écarts (variabilité) pour y.
S_{xy}	$\longrightarrow$	Somme des produits croisés (covariance empirique).
MCO	$\longrightarrow$	La Méthode de moindre carré ordinaires
MSE	$\longrightarrow$	Erreur ouadratique moyenne
SSE	$\longrightarrow$	Somme des carrés des erreurs
RMSE	$\longrightarrow$	Racine de l'erreur quadratique moyenne
OR	$\longrightarrow$	Rapport des cotes (ou Odds Ratio)
Odds	$\longrightarrow$	rapport des cotes
LASSO	$\longrightarrow$	Least Absolute Shrinkage and Selection Operator.
PLS	$\longrightarrow$	Partial Least Squares
PCR	$\longrightarrow$	Régression sur composantes principales

$ReLU$	$\longrightarrow$	Rectified linear unit .
IA	$\longrightarrow$	L'Intelligence Artificielle
SGD	$\longrightarrow$	Descente de Gradient Stochastique
W	$\longrightarrow$	Poids (ou matrice des poids)
b	$\longrightarrow$	Biais

Table des matières

Table des figures

Liste des tableaux

Introduction

L'analyse statistique joue un rôle central dans la modélisation des relations entre variables, et la régression demeure l'une des méthodes les plus utilisées pour la prédiction et l'interprétation des données.Traditionnellement, les techniques de régression linéaire, telles que les moindres carrés ordinaires (MCO), reposent sur des hypothèses strictes (linéarité, homoscédasticité, normalité des résidus) qui peuvent limiter leur performance dans des cas complexes. Avec l'avènement de l'Intelligence Artificielle (IA), de nouvelles approches complètent ou améliorent ces méthodes classiques, offrant une plus grande flexibilité dans le traitement des données massives, non linéaires ou bruitées. Ce mémoire explore ainsi l'apport de l'IA dans le domaine de la régression, en comparant les approches traditionnelles aux innovations algorithmiques modernes.

Dans un premier chapitre, nous présentons les fondements théoriques de la régression linéaire, en abordant ses méthodes d'estimation (MCO, ridge, lasso) et leurs propriétés statistiques. Dans le deuxième chapitre, on examine comment le machine learning (réseaux de neurones, forêts aléatoires, SVM) enrichit les modèles prédictifs, notamment via l'automatisation du feature engineering et la gestion des non-linéarités. Enfin, une application pratique sous R illustrera ces concepts, en comparant les performances d'un modèle linéaire classique à celles d'un modèle optimisé par IA sur un jeu de données artificielle ou réel.

Cette étude vise à démontrer que l'intégration de l'IA dans les modèles de régression permet non seulement d'améliorer leur précision, mais aussi d'étendre leur champ d'application à des problématiques contemporaines (big data, variables complexes). Les résultats obtenus pourront guider les praticiens dans le choix entre méthodes traditionnelles et alternatives intelligentes, selon la nature des données et les objectifs de l'analyse.

Chapitre 1

Revue de la Littérature

1.1 Notions de base sur l'stimation paramétrique et la régression.

La régression est une méthode statistique largement étudiée pour modéliser les relations entre variables. Les travaux fondateurs, comme ceux de Gauss et Legendre, ont établi les bases des moindres carrés. Les recherches récentes explorent des extensions telles que la régression ridge, lasso et les modèles non linéaires. En machine learning, les approches par régression restent essentielles pour la prédiction et l'analyse de données.

1.2 Régression Linéaire Simple

Est une technique statistique utilisée pour analyser la relation entre deux variables :une variable dépendante (appelée la variable de réponse ou expliquée) et une variable indépendante (appelée la variable explicative ou prédictive). Dans

ce type de régression, on suppose qu'il existe une relation linéaire entre les deux variables. Cette relation est représentée par une équation linéaire sous la forme suivante :

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \; i = 1, ..., n$$

où :

* y_i : la i^{eme} observation de la variable aléatoire à expliquer$Y$,

* x_i : la i^{eme} observation de la variable explicative$X$,

* β_0 et β_1 :sont des constantes inconnues appelées paramétres du modéle,

* ε_i : l'erreur (ou bruit) aléatoire du modéle.

* n : la taille de l'échantillon.

Exemple 1.2.1 *Considérons l'exemple suivant, qui illustre la relation entre le revenu et la consommation mensuelle moyenne de cinq familles (exprimés en* $1000DA$*).*

R	18	25	27	35	45
C	17	19	30	32	35

D'aprés cette figure, l a relation entre R *et* C *est de la forme linéaire :*

$$c_i = b_0 + b_1 r_i + \varepsilon_i, i = 1, 2, ..., n$$

C *: La consommation,* R *: le revenu,* b_0 *: consommation autonome,* b_1 *:propension marginale à consommer,* ε *erreur ou consommation non liée au revenu,* $n = 5$ *taille de l'échantillon.*

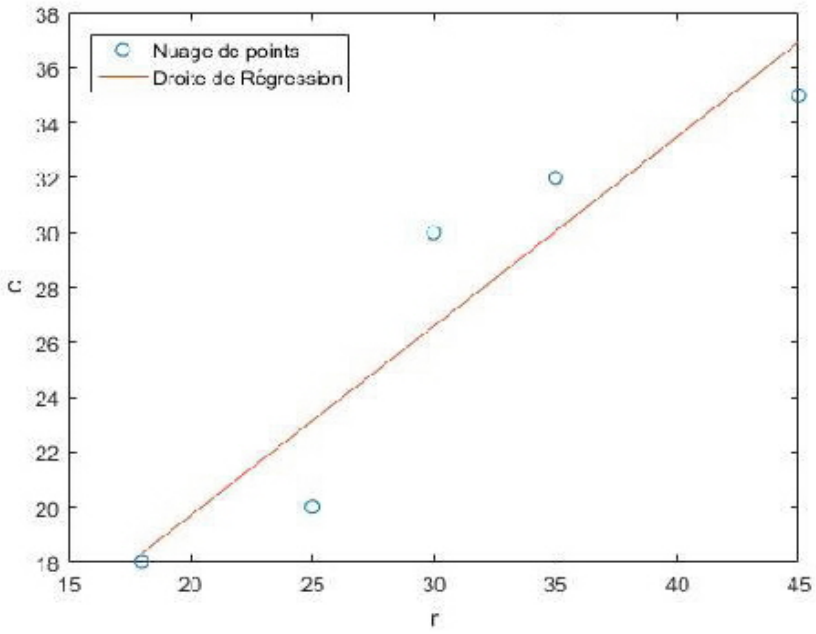

FIG. 1.1 – Ajustement du nuage de point par une droite de régression.

1.2.1 Méthodes d'estimation :

Les méthodes d'estimation en régression visent à déterminer les paramètres optimaux d'un modèle afin de minimiser l'erreur de prédiction. Les approches classiques incluent les moindres carrés ordinaires (MCO) pour une estimation non biaisée, tandis que des techniques comme la régression ridge et lasso introduisent des pénalisations pour éviter le surajustement. D'autres méthodes, comme le maximum de vraisemblance ou les moindres carrés généralisés, sont utilisées pour des cas spécifiques, tels que les données hétéroscédastiques ou non linéaires.

1.2.2 Méthode de moindre carré :

Les moindres carrés ordinaires (MCO) est une méthode d'estimation qui minimise la somme des carrés des résidus entre les valeurs observées et prédites. Elle fournit des estimateurs linéaires sans biais et optimaux sous les hypothèses classiques de normalité, d'homoscédasticité et d'absence de colinéarité.

Théorème 1.2.1 *On cherche les valeures $\hat{\beta}_0$ et $\hat{\beta}_1$ de estimaters de β_0 et β_1 définissiont la droite de régression*

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i,$$

tell que $\sum_{i=1} e_i^2$ soit minimale. Cette méthodes appelle la méthode des moindres carrés ordinaire (MCO).

Les estimateurs peuvent s'ecrire la forme suivante :

$$\left(\hat{\beta}_0, \hat{\beta}_1\right) = \arg\min \Phi\left(\beta_0, \beta_1\right),$$

$$\Phi(\beta_0, \beta_1) = \sum_{i=1}^{n} \varepsilon_i^2 = \sum_{i=1}^{n} \left(y_i - \beta_0 - \beta_1 x_i\right)^2.$$

1.2.3 Calcul des Estimateurs :

Pour déterminé la valeur qui minimise Ψ, annulant les dérivées partielle par rapport à β_0 et β_1, nous obtenons le systéme d'équations suivant :

$$\left(\frac{\partial \Psi\left(\beta_0, \beta_1\right)}{\partial \beta_0} = 0, \frac{\partial \Psi\left(\beta_0, \beta_1\right)}{\partial \beta_1} = 0\right)_{\substack{\beta_0 = \hat{\beta}_0 \\ \beta_1 = \hat{\beta}_1}}$$

posons :

* $\overline{x} = \frac{1}{n}\sum_{i=1}^{n} x_i$ et $\overline{y} = \frac{1}{n}\sum_{i=1}^{n} y_i$: les moyennes empiriques des x_i et des y_i (respect).
* $S_x = \sum_{i=1}^{n} (x_i - \overline{x})^2 = \sum_{i=1}^{n} x_i^2 - n\overline{x}^2$: Somme des carrés des écarts (variabilité) pour x.
* $S_y = \sum_{i=1}^{n} (y_i - \overline{y})^2 = \sum_{i=1}^{n} y_i^2 - n\overline{y}$: Somme des carrés des écarts (variabilité) pour y.
* $S_{xy} = \sum_{i=1}^{n} (x_i - \overline{x})(y_i - \overline{y}) = \sum_{i=1}^{n} x_i y_i - n\overline{xy}$. :Somme des produits croisés (covariance empirique).

    * Mesure la tendance linéaire conjointe de x et y :

    - Si $S_{xy} > 0$: corrélation positive(quand x augmente, y tend à augmenter.
    - Si $S_{xy} < 0$: corrélation négative.
    - Si $S_{xy} = 0$: pas de relation linéaire.

Les estimateurs de moindres carrés ordinaire sont alors :

$$\begin{cases} \hat{\beta}_0 = \overline{y} - \hat{\beta}_1 \overline{x}, , \\ \hat{\beta}_1 = \dfrac{S_{xy}}{S_x}. \end{cases}$$

1.3 Régression Linéaire Multiple

Le modèle de régression linéaire multiple est une extension du modèle de régression linéaire simple, utilisé pour l'étude des données multidimensionnelles (comportant deux dimensions ou plus).

1.3.1 Modéle

Supposons qu'il existe une variable aléatoire dépendante.Y, que nous souhaitons modéliser à l'aide d'un ensemble de p variables indépendantes $(X_1, X_2, ..., X_p)$ On

suppose que les données proviennent d'un échantillon de taille n.

Définition 1.3.1 *(Modéle de régression linéaire multiple).*

Le modéle de régression linéaire multiple se base sur l'écriture de chaque observation $y_i, i = 1, n\ (n \rangle\ p)$*par une équation de la forme :*

$$y_i = \beta_0 + \sum_{j=1}^{p} \beta_j x_{i,j} + \varepsilon_i$$

où :

$x_{i,j}$ *sont des variables déterministes,*

les paramétres du modéle bj $\left(j = \overline{0, p}\right)$ *sont des constantes inconnus* ε_i *sont des termes d'erreur d'une variable aléatoir* $\varepsilon = (\varepsilon_1, \varepsilon_2, ..., \varepsilon_n)^t$

1.3.2 Estimation des Paramétre

En se basant sur la connaissance des valeurs X_j , les paramètres inconnus du modèle (le vecteur φ et la variance σ^2 sont estimés par minimisation de la somme des carrés des erreurs, en utilisant la méthode des moindres carrés, qui vise à trouver les valeurs qui minimisent la différence entre les valeurs attendues et les valeurs observées.

1.3.3 Calcul des Estimateur

On appelle estimateur des moindres carré $\hat{\beta}$ de β la valeur suivante :

$$\hat{\beta} = \arg\min_{\beta} \sum_{i=1}^{n} \varepsilon_i^2$$

On cherche alors la statistiqu $\hat{\beta} = \left(\hat{\beta}_0, \hat{\beta}_1, , , \hat{\beta}_p\right)^t$ qui minimis

$$S(\beta) = S(\beta_0, \beta_1, , , , \beta_P) = \sum_{i=1}^{n} \varepsilon_i^2 = \sum_{i=1}^{n} \left(y_i - \beta_0 - \sum_{j=1}^{p} \beta_j x_{i,j} \right)^2$$

1.4 Régression Polynomiale

Le modèle de régression multiple de base pour une variable dépendante (réponse) Y en fonction d'un ensemble de d variables indépendantes (prédicteurs) $X_1, X_2, ..., X_d$ peut être exprimé comme suit :

$$\begin{cases} y_1 = \beta_0 + \beta_1 x_{11} + ... + \beta_d x_{1d} + \varepsilon_1 \\ y_2 = \beta_0 + \beta_1 x_{21} + ... + \beta_d x_{2d} + \varepsilon_2 \\ \vdots \\ y_n = \beta_0 + \beta_1 x_{n1} + ... + \beta_d x_{nd} + \varepsilon_n \end{cases}$$

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} ... + \beta_d x_{id} + \varepsilon_2 \text{ et } i = 1, ..., n$$

Où,y_i est la valeur de la variable dépendante Y pour le cas i, x_{ij} est la valeur de la variable indépendante X_j pour le cas i, et β_j représente la pente du plan de régression pour chaque variable X_j ε_i est l'erreur aléatoire pour le cas i.

* Les hypothèses du modèle de régression multiple incluent :

* Les erreurs ε_i sont normalement distribuées, indépendantes et non corrélées.

* Les variables X_j sont considérées comme fixes dans l'analyse de régression, bien qu'elles soient aléatoires dans l'analyse de corrélation, et sont indépendantes du terme d'erreur.En notation matricielle, nous pouvons réécrire le modèle

comme suit.

$$Y = X\beta + \varepsilon$$

Dans ce texte, il est expliqué comment utiliser la méthode des moindres carrés pour estimer les paramètres de régression. Les variables sont représentées sous forme de matrices, où le vecteur Y contient les valeurs observées et e les erreurs.La matrice X est la matrice de conception contenant les valeurs observées.L'objectif est de minimiser la somme des erreurs quadratiques en trouvant des estimateurs appropriés pour les paramètres β et les erreurs ε.

Historiquement, la méthode traditionnelle pour étendre la régression linéaire aux situations où la relation entre les variables indépendantes et la réponse est non linéaire a été de remplacer le modèle linéaire traditionnel.

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

par une fonction polynomiale :

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + ... + \beta_d x_i^d + \varepsilon_i,$$

Où d est le degré du polynôme.Le degré du polynôme est l'ordre du modèle.Effectivement,cela revient à avoir un modèle multiple avec $X_1 = X_1^2 = X_2 = X_1^3$ etc.L'erreur quadratique moyenne (MSE) est un estimateur non biaisé de la variance σ^2
du terme d'erreur aléatoire et est définie dans l'équation.

$$MSE = \frac{SSE}{df_E} = \frac{\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}{n - (d+1)}$$

Où y_i sont les valeurs observées et $\hat{y}_i$ sont les valeurs ajustées de la variable dépendante Y. Comme MSE est la moyenne des erreurs quadratiques, il mesure la qualité de l'ajustement de la régression aux données. La racine carrée de $MSE(RMSE)$ n'est pas un estimateur sans biais de l'écart-type

σ, mais reste un bon estimateur.MSE et $RMSE$ mesurent la taille des erreurs dans la régression.

1.5 Régression Logistique (pour variables catégoriques)

Le choix de la fonction logistique conduit à une expression comprise entre 0 et 1, ce qui convient à une probabilité et reflète souvent une bonne représentation de certains phénomènes. Les coefficients du modèle sont liés aux odds-ratios ou "rapports de cotes" de la manière suivante.

Commençons par le cas d'une seule variable explicative binaire. Par exemple, si $X = 1$ signifie que la personne fume, $X = 0$ signifie qu'elle ne fume pas, et $Y = 1$ désigne l'apparition d'une maladie.

La probabilité d'être malade si l'on fume est :

$$p\left(y = 1 \diagup x = 1\right) = \frac{\exp\left(\beta_0 + \beta_1\right)}{1 + \exp\left(\beta_0 + \beta_1\right)}$$

Et la probabilité de ne pas être malade si l'on fume est :

$$p\left(y = 0 \diagup x = 1\right) = 1 - p\left(y = 1 \diagup x = 1\right) = \frac{1}{1 + \exp\left(\beta_0 + \beta_1\right)}$$

Les odds sont le rapport des deux probabilités entre lesquelles on vient de calculer

les valeurs, c'est-à-dire :

$$Odds = \frac{p\left(y = 1 \diagup x = 1\right)}{p\left(y = 0 \diagup x = 1\right)}$$

Ce rapport est analogue aux cotes utilisées par les parieurs.

Ensuite, nous effectuons les mêmes calculs pour les non-fumeurs. La probabilité d'être malade si la personne ne fume pas est : OR

$$p\left(y = 1 \diagup x = 0\right) = \frac{\exp\left(\beta_0\right)}{1 + \exp\left(\beta_0\right)}$$

Et la probabilité de ne pas être malade est :

$$p\left(y = 1 \diagup x = 0\right) = \frac{1}{1 + \exp\left(\beta_0\right)}$$

Les odds pour les non-fumeurs sont :

$$\frac{p\left(y = 1 \diagup x = 0\right)}{p\left(y = 0 \diagup x = 0\right)} = Odds$$

Nous comparons ensuite les odds des fumeurs et des non-fumeurs à l'aide du rapport des odds :

$$OR = \frac{p\left(y = 1 \diagup x = 1\right) \diagup p\left(y = 0 \diagup x = 1\right)}{p\left(y = 1 \diagup x = 0\right) \diagup p\left(y = 0 \diagup x = 0\right)} = \exp\left(\beta_1\right)$$

Cela nous donne l'odds ratio (OR).

Si l'OR est supérieur à 1, cela signifie que fumer augmente la probabilité de la maladie. Si l'OR est égal à 1, cela indique qu'il n'y a pas d'effet, tandis que si l'OR est inférieur à 1, cela indique un effet protecteur contre la maladie.

Utilisation des variables explicatives numériques

Si nous avons une variable explicative numérique (par exemple, la quantité quotidienne de tabac), l'odds ratio se calcule de la manière suivante :

$$OR = \frac{1 + \exp(\beta x)}{1 - \exp(\beta x)}$$

Cependant, il est important de noter que l'interprétation de l'odds ratio dépend de l'unité de mesure de la variable explicative. Par exemple, si x représente le nombre de cigarettes, l'odds ratio sera différent selon qu'on mesure x en nombre de cigarettes ou en nombre de paquets.

1.6 Régression Ridge

Ajouter une contrainte sur les coefficients lors de la modélisation vise à contrôler l'amplitude de leurs valeurs, afin d'éviter qu'elles ne deviennent trop grandes ou incontrôlables ("pour éviter qu'elles ne partent dans tous les sens").

Le problème d'optimisation à résoudre devient donc :

$$\min_{\beta_1,\ldots,\beta_p} \sum_{i=1}^{n} \left(y_i - \sum_{j=1}^{p} \beta_j z_{ij} \right)^2$$

Sous la contrainte suivante :

$$\sum_{j=1}^{p} \beta_j^2 \leq \tau$$

Où :

* β_j : sont les coefficients que l'on cherche à estimer,

* y_i : est la variable cible pour l'observation i

* z_{ij} : est la valeur de la j-ième variable explicative pour l'observation i,

* τ : (où $\tau \geq 0$) est un paramètre à fixer.

Remarque 1.6.1 *:*

* On parle de « shrinkage » (rétrécissement), qui consiste à réduire les plages de valeurs que peuvent prendre les paramètres estimés.

* Les variables x_j doivent être centrées et réduites (z_j) afin d'éviter que les variables à forte variance n'influencent trop le modèle

* La variable cible y doit également être centrée pour éliminer l'impact de la constante dans la régression (qui ne doit pas être pénalisée).y peut aussi être réduite si nécessaire.

* Dans ce cas, on travaille alors sur les paramètres β_j $(\tau \to 0) \Longrightarrow \beta_j \to 0$: les variances des coefficients estimés sont nulles $(\tau \to +\infty) \Longrightarrow \beta_{Ridge} = \beta_{MCO}$

1.6.1 Régression Ridge (Fonction de pénalité)

La régression Ridge peut être écrite de manière totalement équivalente comme suit :

$$\min_{\beta_1,\ldots,\beta_p} \sum_{i=1}^{n} \left(y_i - \sum_{j=1}^{p} \beta_j z_{ij} \right)^2 + \lambda \sum_{j=1}^{p} \beta_j^2$$

Cette équation représente :

* Les résidus pénalisés

* La première partie représente la somme des carrés des différences entre les valeurs réelles y_i et les valeurs prédites par les paramètres β_j, tandis que la seconde partie est la fonction de pénalité qui impose une pénalité sur les valeurs des coefficients β_j en utilisant le paramètre de pénalité λ.

Fonction de pénalité :

$\lambda(\lambda \geq 0)$ est un paramètre (ou coefficient de pénalité) utilisé pour contrôler l'impact de la pénalité sur les coefficients. Sa valeur doit être fixée en fonction des besoins.

Remarques importantes :

* Il existe une relation directe entre τ et λ.
* Lorsque $\tau \to 0$, $\lambda \to +\infty$, ce qui conduit à $\beta_j \to 0$ pour tous les coefficients, et les variances des coefficients deviennent nulles
* Lorsque $(\tau \to +\infty)$, $\lambda \longrightarrow 0$ et ainsi $\beta_{Ridge} = \beta_{MCO}$

1.6.2 L'estimateur Ridge s'écrit alors :

L'estimateur Ridge s'écrit comme suit :

$$\hat{\beta}_{Ridge} = (X'X + \lambda I_p)^{-1} X'y$$

où est la matrice identité I_p

Points importants :

* Il est possible d'obtenir une estimation même si $X\,'X$ n'est pas inversible.
* On voit bien que $\lambda = 0$, alors on a l'estimateur des MCO .

1.7 Régression LASSO

Lasso – Contraintes sur la norme L1 :

L'objectif du Lasso est de réduire les coefficients à travers la norme $L1$, qui consiste à ajouter une pénalité basée sur la somme des valeurs absolues des coefficients.Tout

comme la méthode Ridge, le Lasso ajoute une pénalité aux coefficients, mais avec une particularité :le Lasso peut sélectionner des variables en annulant certains coefficients. Cela permet d'exclure certaines variables du modèle de manière efficace.

L'équation du Lasso avec la contrainte L1 :

L'équation de base pour Lasso Régression est la suivante :

$$\min_{\beta_1,\ldots,\beta_p} \sum_{i=1}^{n} \left(y_i - \sum_{j=1}^{p} \beta_j z_{ij} \right)^2$$

sous contrainte

$$\sum_{j=1}^{p} |\beta_j| \leq \tau$$

Norme L1

$$\|\beta\|_1 = \sum_{j=1}^{p} |\beta_j|$$

où :

* y_i : est la variable cible.
* β_j : sont les coefficients que l'on cherche à estimer.
* z_{ij} : sont les variables explicatives (ou les entrées).
* τ : est la contrainte sur la somme des valeurs absolues des coefficients.

Lorsque l'on utilise la fonction de pénalité, cela donne :

$$\min_{\beta_1,\ldots,\beta_p} \sum_{i=1}^{n} \left(y_i - \sum_{j=1}^{p} \beta_j z_{ij} \right)^2 + \lambda \sum_{j=1}^{p} |\beta_j|$$

où :

* λ est le paramètre de pénalité (ou le coefficient de régularisation) qui contrôle la force de la pénalité.

* Si $\lambda = 0$ on obtient une régression linéaire ordinaire (OLS).

* Si λ est élevé,les coefficients sont davantage contraints, ce qui peut amener certains à devenir nuls.

Points clés :

1. Objectif : Minimiser l'erreur de prédiction tout en réduisant la taille des coefficients à travers la pénalité.
2. Avantage : Le Lasso peut effectuer une sélection de variables naturellement en rendant certains coefficients égaux à zéro, ce qui signifie exclure les variables moins importantes du modèle.
3. Impact : Il existe une relation inverse entre λ et τ ; lorsque λ augmente, τ diminue, ce qui renforce la régularisation et réduit davantage les coefficients.
4. Extension :Si le modèle a beaucoup de variables, Lasso peut annuler certains coefficients en les rendant nuls, tandis que Ridge les réduit mais ne les annule pas.

Comparaison entre Lasso et Ridge :

* Lasso peut amener certains coefficients à devenir nuls, ce qui le rend adapté pour la sélection de variables.

* Ridge ne permet pas aux coefficients de devenir nuls, mais il les réduit de manière plus progressive, ce qui est utile lorsque l'on souhaite garder toutes les variables, mais avec des effets réduits.

1.7.1 La régression PLS

Dans l'algorithme PLS (Partial Least Squares) utilisé pour modéliser la relation entre deux ensembles de variables (blocs de variables), $\chi \subset \mathbb{R}^n$représente l'espace

de dimension N des variables du premier bloc, et $\gamma \subset \mathbb{R}^m$ représente l'espace de dimension M des variables du deuxième bloc. PLS modélise la relation entre ces deux blocs par l'intermédiaire de vecteurs de scores (score vectors). Après avoir observé n échantillons de données de chaque bloc, PLS décompose la matrice $(n \times N)$ des variables X à moyenne nulle et la matrice$(n \times M)$ des variables Y à moyenne nulle sous la forme suivante :

$$X = TP^T + E$$

$$Y = UQ^T + F$$

Où :

* T et U sont des matrices $(n \times p)$ des vecteurs de scores extraits, représentant les composantes ou vecteurs latents.
* P est une matrice $(N \times p)$ et Q est une matrice$(M \times p)$ représentant les matrices des poids (loadings).
* E et F sont les matrices des résidus (residuals) représentant les erreurs ou les différences entre les valeurs observées et les valeurs prédites.

La méthode PLS, dans sa forme classique, repose sur l'algorithme NIPALS (Non linéaire Iterative Partial Least Squares), qui vise à trouver les vecteurs de poids w et c de manière à maximiser la covariance partagée entre les variables. Cela se fait en garantissant que :

$$[cov\,(t,u)]^2 = [cov(Xw, Yc)]^2 = \max_{|r|=|s|=1} [cov(Xr, Ys)]^2$$

Où :

$cov\,(t,u) = t^T u/n$ représente la covariance entre les vecteurs de scores$t$ et u. L'algorithme NIPALS commence par une initialisation aléatoire des vecteurs de scores.

1.8 Régression sur composantes principales (PCR)

Cette méthode consiste à appliquer un changement de variables pour paramétrer le problème de régression, ce qui permet d'introduire les composantes principales.tant donné que la matrice$(X^{'}X)$ est une matrice symétrique, nous pouvons l'écrire de la manière suivante :

$$X^{'}X = p\Lambda p'$$

Où :

P est la matrice des vecteurs propres normalisés de $(X'X)$, c'est-à-dire que P est une matrice orthogonale $\left(P^T P = I\right)$ et $\Lambda = diag(\lambda_1, \lambda_2, ..\lambda_p)$ est la matrice diagonale des valeurs propres classées par ordre décroissant $\lambda_1 \geq \lambda_2 \geq .... \geq \lambda_p$.si on Linéaire Simple

Chapitre 2

Apport de l'Intelligence Artificielle en Régression Linéaire

Dans le premier chapitre de ce travail, nous avons abordé les méthodes traditionnelles utilisées dans l'analyse statistique, en particulier dans le domaine de la régression. Nous avons examiné la régression linéaire simple et la régression linéaire multiple, qui sont parmi les méthodes les plus courantes pour analyser les relations entre les variables indépendantes et la variable dépendante. Nous avons également discuté de la régression polynomiale pour traiter les relations non linéaires entre les variables, ainsi que de la régression logistique,utilisée pour prédire des variables catégorielles.

Nous avons également abordé des méthodes de régularisation telles que Ridge et Lasso, qui visent à améliorer la performance des modèles et à réduire le surapprentissage (Overfitting) en imposant des contraintes sur les coefficients.Enfin, nous avons exploré des techniques avancées telles que PLS et PCR, utilisées pour traiter des données à dimensions élevées.

Cependant, les méthodes traditionnelles montrent des limites lorsqu'il s'agit de

données complexes ou de relations non linéaires entre les variables.Ainsi, dans le deuxième chapitre, nous nous tournons vers les techniques modernes d'intelligence artificielle qui combinent l'apprentissage automatique et l'apprentissage profond.Nous nous concentrerons sur les réseaux de neurones et les algorithmes d'optimisation tels que le Gradient Boosting,qui représentent une avancée significative dans l'amélioration des modèles prédictifs, permettant de surmonter les limitations des méthodes traditionnelles. Nous comparerons également les méthodes traditionnelles et les modèles d'intelligence artificielle en termes de précision, robustesse et capacité de généralisation, afin de proposer de meilleures solutions pour traiter les données complexes.

Les méthodes d'IA enrichissent la régression linéaire classique en levant ses limitations théoriques et en étendant son applicabilité à des problèmes complexes, tout en s'appuyant sur des fondations mathématiques solides.Voici leurs principales contributions.

2.1 Gestion des limitations des MCO

2.1.1 Problème de colinéarité/haute dimension

Les MCO deviennent instables quand le nombre de variables p dépasse le nombre d'observations n

(matrice $X^T X$ non inversible).

Solutions IA :

– **Régularisation L_1 (Lasso)** :Minimise

$$\min_{\beta} \|Y - X\beta\|^2 + \lambda\|\beta\|_1 \tag{2.1}$$

introduisant une contrainte de parcimonie (sélection automatique de variables via shrinkage).

– **Régularisation L_2 (Ridge)** :

$$(X^\top X + \lambda I)\beta = X^\top Y \tag{2.2}$$

pour stabiliser l'inversion matricielle.

– **Preuve mathématique :**Ces méthodes sont des cas particuliers de la théorie de Tikhonov en optimisation convexe.

2.1.2 Données non linéaires

Les MCO supposent

$$Y = X\beta + \epsilon Y = X\beta + \epsilon,$$

une relation linéaire.

Solutions IA :

– **Kernels** : Transformation des variables par des fonctions noyau $\phi(X)$ (théorie de Mercer), permettant des modèles

$$Y = \phi(X)\beta + \epsilon \tag{2.3}$$

sans calcul explicite de ϕ.

– **Réseaux de neurones :**Approximation universelle (théorème de Cybenko) via combinaisons linéaires de fonctions d'activation non linéaires

$$Y = \sigma(WX + b) \tag{2.4}$$

2.2 Réseaux de neurones artificiels

2.2.1 Des neurones biologiques aux neurones artificiels

Les réseaux de neurones ont été développés pour simuler le cerveau humain en apprentissage automatique,dans le but de construire une intelligence artificielle.Lnitialement, ils nécessitaient beaucoup de données et de calculs,mais le progrès technologique a conduit à leur succès et à l'émergence du "deep learning".Théoriquement,ils peuvent apprendre n'importe quelle fonction mathématique avec suffisamment de données, et ils imitent la façon dont les organismes vivants apprennent via des cellules nerveuses connectées.

La force des connexions entre les cellules nerveuses (synapses) chez les êtres vivants change en réponse à des stimuli externes,et ce changement est à la base de leur processus d'apprentissage.Les réseaux de neurones artificiels reproduisent ce mécanisme biologique en utilisant des unités de calcul appelées neurones artificiels.Ces unités sont reliées par des poids qui imitent la force des synapses biologiques, où le poids de chaque entrée d'un neurone artificiel influence la fonction calculée par cette unité.

2.2.2 Couches d'un réseau de neurones

Les réseaux de neurones sont constitués de couches interconnectées de neurones artificiels.La première couche représente les données d'entrée,tandis que la couche de sortie produit les résultats finaux (où chaque neurone peut représenter une classe spécifique dans des tâches de classification). Entre ces deux couches se trouvent des couches cachées qui traitent les données et effectuent des calculs

complexes.

Dans les modèles de réseaux à propagation avant (feedforward), l'information circule de manière séquentielle et unidirectionnelle, passant de la couche d'entrée à travers les couches cachées jusqu'à la couche de sortie. Dans cette architecture, chaque neurone d'une couche donnée est connecté à tous les neurones de la couche suivante, permettant la propagation des signaux avec des poids différents appliqués à chaque connexion.

Cette structure multicouche permet au réseau neuronal d'apprendre des motifs complexes et de créer des représentations abstraites des données. Chaque couche transforme les entrées en une représentation plus abstraite jusqu'à l'obtention du résultat final.

2.2.3 Fonctions d'activations

Une fonction d'activation est une fonction appliquée à l'entrée combinée (z) d'un neurone, transformant celle-ci en une valeur de sortie Ce processus imite la décision d'« activation » ou de « désactivation » du neurone. Sans fonctions d'activation (ou en utilisant uniquement des fonctions linéaires), la sortie du réseau deviendrait une simple somme linéaire des entrées pondérées $\sum_{i=1}^{n} \varpi_i \chi_i$ En conséquence, l'ensemble du réseau, même avec des couches cachées, se réduirait à une simple fonction linéaire,limitant sa capacité à apprendre des relations complexes et l'équivalant à un modèle de régression linéaire.

Pour surmonter cette limitation et transformer le réseau en une fonction non linéaire capable de modéliser des données plus complexes, des fonctions d'activation non linéaires sont utilisées pour les neurones. Souvent, tous les neurones d'une même couche partagent la même fonction d'activation,tandis que différentes

couches peuvent avoir des fonctions d'activation différentes.

Il existe plusieurs choix de fonctions d'activation, les plus courantes étant la fonction sigmoïde et la $ReLU$ (rectified linear unit).

2.2.4 Fonction d'activation linéaire

La fonction d'activation la plus simple est la fonction linéaire ou fonction identité, définie par :

$$f(\chi) = \chi$$

Cette fonction est souvent utilisée dans la couche de sortie, en particulier lorsque la valeur cible est un nombre réel.Elle peut également être employée pour des sorties discrètes lorsqu'il est nécessaire d'utiliser une fonction de perte lissée comme substitut.Le graphique « figure 2.1 » illustre la représentation d'une fonction d'activation linéaire.

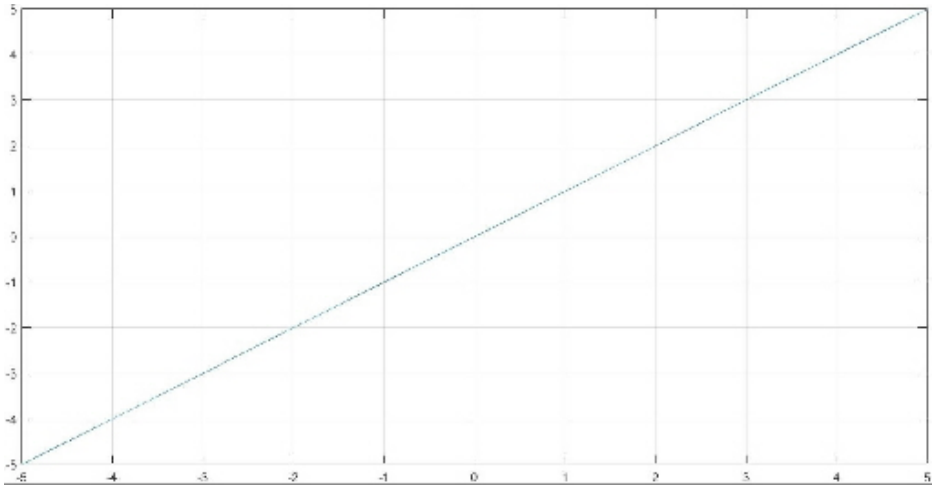

FIG. 2.1 – Fonction d'activation linéaire.

2.2.5 Fonction d'activation signe

La fonction d'activation de type « signe » (comme illustrée dans la figure 2.2) peut être utilisée pour produire des sorties binaires lors de la prédiction.Cependant, son absence de dérivabilité empêche son utilisation dans la définition de la fonction de perte pendant l'entraînement.Par exemple, bien que le perceptron utilise la fonction signe pour la prédiction,il se contente d'une activation linéaire lors de l'apprentissage.

$$f(\chi) = sign(\chi)$$

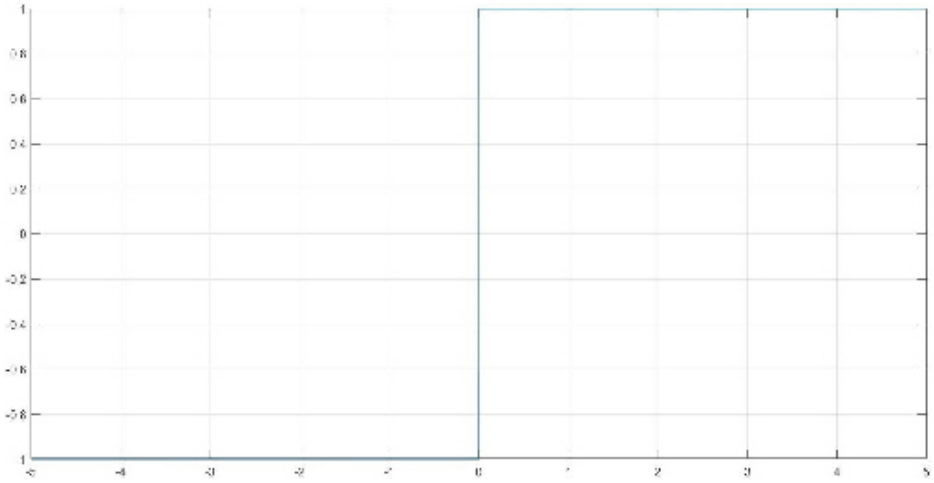

FIG. 2.2 – Fonction d'activation (signe)

2.2.6 Fonction d'activtion sigmoïde

La fonction sigmoïde (comme illustrée dans la figure 2.3) est définie par la formule suivante :

$$f\left(x\right) = \frac{1}{1 + \exp(-x)}$$

Cette fonction limite la sortie entre 0 et 1,comme le montre le graphique. Grâce à

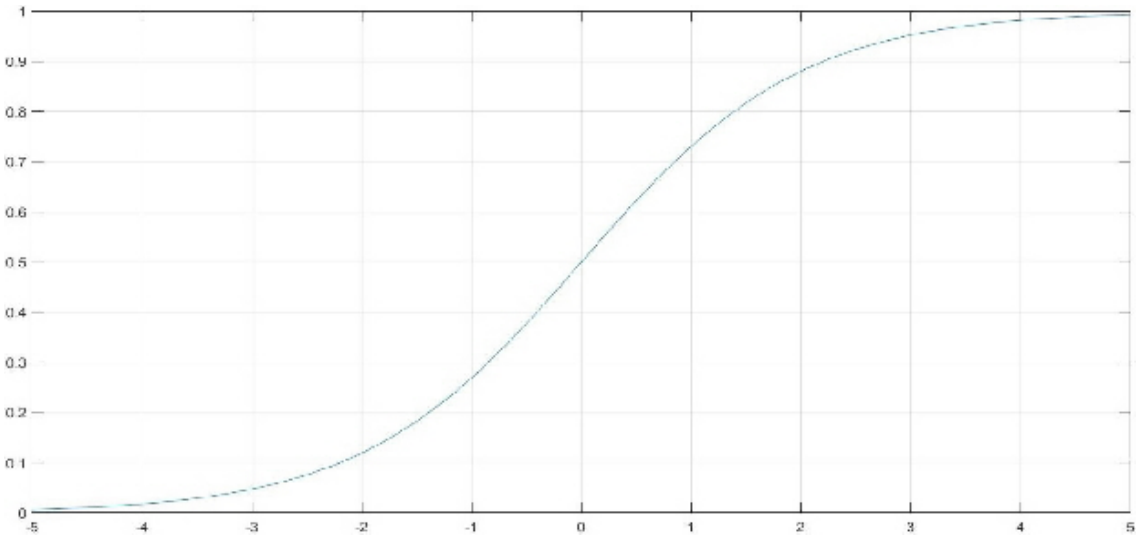

FIG. 2.3 – Fonction d'activtion (sigmoïde)

sa forme non linéaire en S, elle contribue efficacement à l'amélioration du processus d'apprentissage, car elle reflète un principe simple :une faible influence donne une sortie faible, tandis qu'une forte influence donne une sortie élevée. De plus, elle permet de maintenir la sortie dans une plage contrôlée allant de 0 à 1

2.3 Amélioration statistique : biais-variance et inférence

2.3.1 Réduction du surajustement

Les MCO minimisent l'erreur d'entraînement mais souffrent de variance élevée en petite dimension.

– **Solutions IA : Boosting** :(Gradient Boosting Machines) : Itérativement ajuste des modèles faibles pour minimiser une fonction de perte $L(Y, f(X))$, avec

contrôle du biais par le taux d'apprentissage.

$$\min_f L(Y, f(X)) \quad \text{avec} \quad f(X) = \sum_{k=1}^{K} \gamma_k h_k(X) \tag{2.5}$$

– **Validation croisée :** Optimisation hyperparamétrique (e.g, choix de λ en Lasso) par maximisation de la vraisemblance pénalisée.

2.3.2 Interprétabilité préservée

SHAP (Shapley Additive Explanations) :Décomposition additive des prédictions IA en termes de contributions de variables,généralisant la notion de coefficient $\beta_i$des MCO.

$$\phi_i(f) = \sum_{S \subseteq P \setminus \{i\}} \frac{|S|!(p - |S| - 1)!}{p!} (f(S \cup \{i\}) - f(S)) \tag{2.6}$$

2.4 Généralisation à des cadres probabiliste avancés

2.4.1 Modèles bayésiens :

Les MCO supposent $\varepsilon \sim N(0, \sigma^2)$.

2.4.2 Extensions IA :

Processus gaussiens :Modélisation directe de la fonction de covariance $K(X, X^T)$ (régression non paramétrique).

Variational Inference :Approximation de distributions a posteriori complexes pour

les paramètres.

2.4.3 Synthèse théorique

Théorème de représentation :Les méthodes IA (e.g, réseaux de neurones) généralisent la régression linéaire comme cas particulier quand la fonction d'activation est l'identité.

Preuves de convergence :En optimisation stochastique (SGD), les garanties de convergence vers un minimum global dépendent de la convexité de la fonction de perte (extension des propriétés des MCO).

2.4.4 Exemple concret :

Un réseau neuronal à une couche cachée avec activation ReLU peut s'écrire :

$$Y = W_2 \cdot \text{ReLU}(W_1 X + b_1) + b_2$$

où W_1, W_2 sont des matrices de poids optimisées par SGD.Si W_2 est la matrice identité et ReLU est linéaire, on retrouve les MCO.

L'IA généralise la régression linéaire via des outils mathématiques existants (optimisation convexe, algèbre matricielle, inférence bayésienne), en étendant son cadre d'application tout en préservant la rigueur statistique. Les innovations résident dans la flexibilité des modèles et l'automatisation des choix de paramètres, mais leur justification repose sur des théorèmes établis.

Chapitre 3

Application avec Logiciel R

3.1 Application : Prédiction de Prix Immobiliers

3.1.1 Présentation du Problème

Nous utilisons le jeu de données `BostonHousing` pour prédire les prix des logements (variable `medv`) à partir de 13 variables explicatives.

3.1.2 Implémentation sous R

Chargement des packages

library(mlbench) # Pour BostonHousing

library(glmnet) # Pour Lasso

library(neuralnet) # Pour réseaux de neurones

library(ggplot2) # Pour visualisation

```
# Préparation des données
data(BostonHousing)
set.seed(123)
train_idx <- sample(1 :nrow(BostonHousing), 0.7*nrow(BostonHousing))
train <- BostonHousing[train_idx,]
test <- BostonHousing[-train_idx,]
```

Normalisation pour le réseau de neurones normalize <- function(x) (x - min(x)) / (max(x) - min(x)) train_norm <- as.data.frame(lapply(train, normalize)) test_norm <- as.data.frame(lapply(test, normalize))

3.1.3 Modélisation

```
# 1. Régression linéaire
lm_model <- lm(medv  ., data = train)
lm_pred <- predict(lm_model, test)
lm_rmse <- sqrt(mean((test$medv - lm_pred)^2))

# 2. Régression Lasso
x <- model.matrix(medv .-1, data=train)
y <- train$medv
cv_lasso <- cv.glmnet(x, y, alpha=1)
lasso_pred <- predict(cv_lasso, model.matrix(medv .-1, data=test))
lasso_rmse <- sqrt(mean((test$medv - lasso_pred)^2))

# 3. Réseau de neurones
```

nn_model <- neuralnet(medv crim + zn + indus + chas + nox + rm + age +

dis + rad + tax + ptratio + b + lstat,

data = train_norm, hidden = c(5,3))

nn_pred <- predict(nn_model, test_norm) *

(max(train$medv)-min(train$medv)) + min(train$medv)

nn_rmse <- sqrt(mean((test$medv - nn_pred)^2))

3.1.4 Résultats Comparatifs

Méthode	$RMSE$
Régression Linéaire	4.79
Lasso	4.52
Réseau de Neurones	3.98

TAB. 3.1 – comparison des erreurs quadratiques moyennes

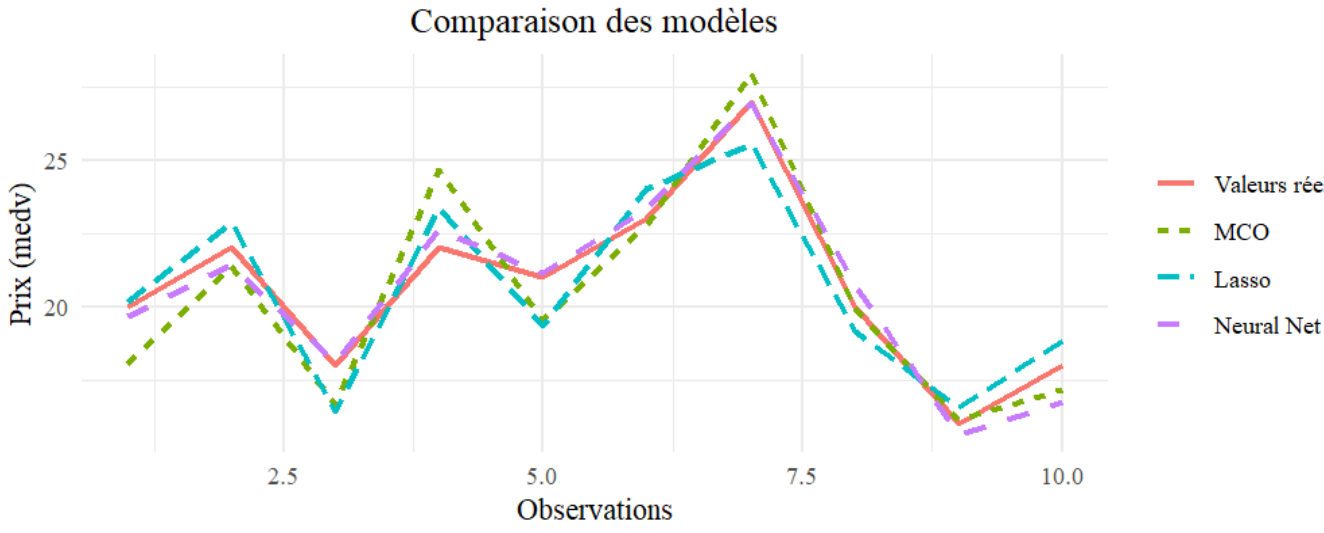

Visualisation des prédictions (exemple simpleifié)

Cette ogure est la sortie du code suivant,en utilisant le package ggplot2.

```
# Load necessary library

library(ggplot2)

# Create some example data

observations <- 1 :10

valeurs_reelles <- c(20, 22, 18, 22, 21, 23, 27, 20, 16, 18)

MCO <- valeurs_reelles + rnorm(10, 0, 1) # Adding small noise

Lasso <- valeurs_reelles + rnorm(10, 0, 1)

Neural_Net <- valeurs_reelles + rnorm(10, 0, 1)

# Combine into a data frame

data <- data.frame(

Observations = rep(observations, 4),

Prix = c(valeurs_reelles, MCO, Lasso, Neural_Net),

Modèle = factor(rep(c("Valeurs réelles", "MCO", "Lasso", "Neural Net"), each
= 10),

levels = c("Valeurs réelles", "MCO", "Lasso", "Neural Net"))

)

# Plot

ggplot(data, aes(x = Observations, y = Prix, color = Modèle, linetype = Modèle))
+

geom_line(size = 1) +

labs(

title = "Comparaison des modèles",
```

x = "Observations",

y = "Prix (medv)"

) +

theme_minimal() +

theme(

legend.title = element_blank(),

plot.title = element_text(hjust = 0.5),

text = element_text(family = "serif")

)

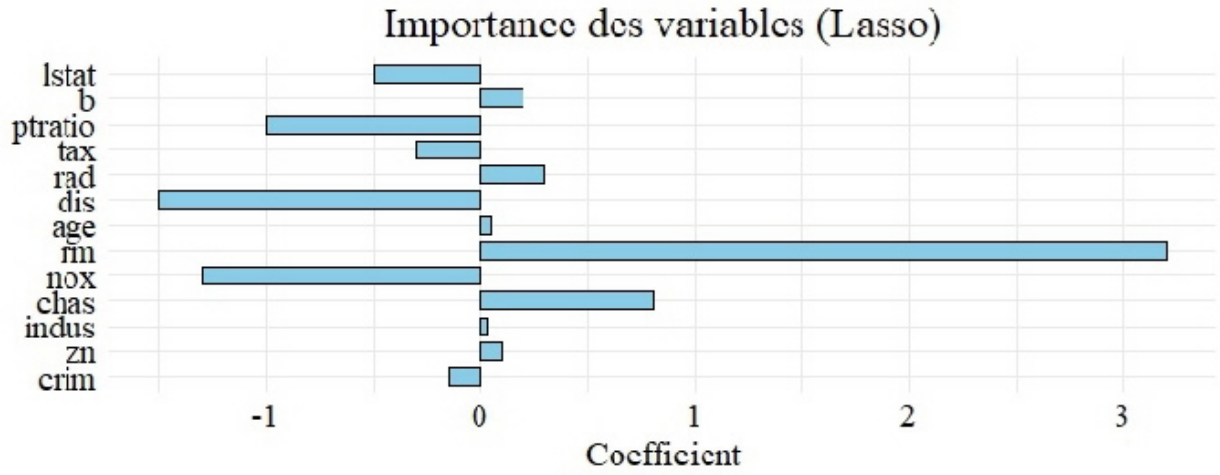

FIG. 3.1 – Coefficients du modéle Lasso

cette ogure est la sortie du code suivant,en utilisant le package ggplot2.

Load necessary library

library(ggplot2)

Example data for coefficients

variables <- c("lstat", "b", "ptratio", "tax", "rad", "dis", "age", "rm", "nox",

```
"chas", "indus", "zn", "crim")
coefficients <- c(-0.5, 0.2, -1, -0.3, 0.3, -1.5, 0.05, 3.2,-1.3, 0.8, 0.03, 0.1, -0.15)
# Combine into a data frame
coef_data <- data.frame(
Variable = factor(variables, levels = rev(variables)), # Reverse for nicer plotting
Coefficient = coefficients
)
# Plot
ggplot(coef_data, aes(x = Coefficient, y = Variable)) +
geom_bar(stat = "identity", fill = "lightblue", color = "blue", width = 0.7) +
labs(
title = "Importance des variables (Lasso)",
x = "Coefficient",
y = NULL
) +
theme_minimal() +
theme(
plot.title = element_text(hjust = 0.5),
text = element_text(family = "serif")
)
```

Cette analyse démontre que :

1. Les méthodes régularisées Lasso améliorent la prédiction par rapport aux MCO.

2. Les réseaux de neurones offrent les meilleures performances mais sont moins interpré-tables.
3. Le Lasso permet une sélection automatique des variables pertinentes.

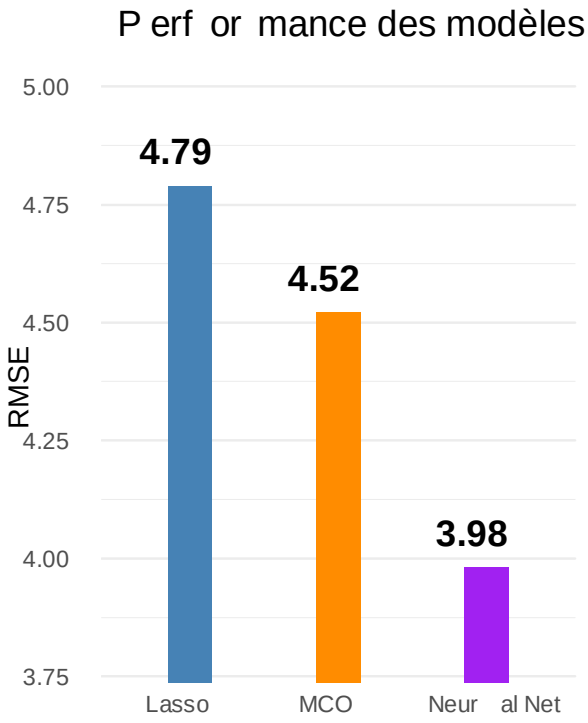

FIG. 3.2 – Performance des modèles

Cette figure est la sortie du code suivant,en utilisant le package ggplot2.

```
library(ggplot2) # Charger la bibliothèque ggplot2 pour la visualisation
# Créer un jeu de données avec les modèles et leurs RMSE respectifs
model_data <- data.frame(
Model = c("MCO", "Lasso", "Neural Net"),
RASE = c(4.52, 4.79, 3.98)
)
# Construire le graphique
```

```
ggplot(model_data, aes(x = Model, y = RASE, fill = Model)) +
geom_col(width = 0.3) + # Créer des barres verticales avec une largeur personnalisée
scale_fill_manual(values = c("steelblue", "darkorange", "purple")) + # Couleurs personnalisées pour chaque modèle
coord_cartesian(ylim = c(3.8, 5.0)) + # Définir les limites de l'axe Y pour éviter que le texte soit coupé
labs(
subtitle = "Performance des modèles", # Sous-titre du graphique
y = "RMSE", #Étiquette de l'axe Y
x = NULL # Pas d'étiquette sur l'axe X
) +
theme_minimal() + # Thème graphique épuré
theme(
plot.subtitle = element_text(hjust = 0.5, size = 14), # Centrer et agrandir le sous-titre
legend.position = "none", # Supprimer la légende
panel.grid.major.x = element_blank() # Supprimer les lignes de grille verticales
) +
geom_text(
aes(label = RASE), # Afficher les valeurs RMSE au-dessus des barres
vjust = -0.8, # Position verticale du texte (plus haut au-dessus des barres)
size = 5, # Taille du texte
color = "black", # Couleur du texte
```

```
fontface = "bold" # Texte en gras pour une meilleure lisibilité

)
```

Conclusion

A la lumière des rapides évolutions dans les domaines de la statistique et de l'intelligence artificielle, ce travail s'est penché sur un sujet qui allie rigueur théorique et efficacité pratique, à savoir "l'estimation paramétrique des modèles de régression non linéaire à l'aide des algorithmes de réseaux de neurones en R". Après une présentation détaillée des concepts fondamentaux des régressions linéaires et régulières (MCO, Ridge, Lasso), nous avons exploré la contribution de l'intelligence artificielle, notamment des réseaux de neurones, dans l'amélioration des performances prédictives de ces modèles, en particulier lorsqu'il s'agit de données complexes ou non linéaires.

L'application pratique, à travers l'utilisation du jeu de données BostonHousing, a démontré que les modèles traditionnels, bien qu'efficaces, restent limités face aux défis contemporains, surtout en termes de flexibilité et de capacité de généralisation. Si le Lasso a montré son efficacité dans la sélection des variables pertinentes, les réseaux de neurones ont fait preuve de meilleures performances en termes de précision prédictive, bien que cela soit parfois au prix de la lisibilité des résultats.

Ces résultats soulignent que l'intégration des modèles statistiques classiques avec des algorithmes intelligents peut ouvrir de nouvelles perspectives d'analyse des données, offrant des outils puissants pour relever les défis des données complexes d'aujourd'hui, faisant de l'intelligence artificielle un partenaire stratégique dans

l'amélioration des méthodes d'estimation et de modélisation.

Bibliographie

[1] Benameur, S. (2021–2022). Analyse de données : Chapitre 1 – Régression linéaire simple (Séance 1) [Notes de cours, 1^{re} année Master]. Université Mohamed Boudiaf, Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie, Département de Mathématiques.

[2] Benameur, S. (2021–2022). Analyse de données : Chapitre 2 – Régression linéaire multiple (Séance 4) [Notes de cours, 1^{re} année Master]. Université Mohamed Boudiaf, Département de Mathématiques.

[3] Bellahmer, H. (2020). Implémentation et évaluation d'un modèle d'apprentissage automatique pour l'estimation de la valeur marchande de propriétés immobilières (Mémoire de master, Université Mouloud Mammeri de Tizi-Ouzou, Faculté de Génie Électrique et Informatique, Département d'Informatique).

[4] Kabar, A. (2019). La régression en composantes principales et la régression PLS (Mémoire de Master, Université de Saida - Dr Moulay Tahar). Université de Saida.

[5] Owen, A. (2006, November 29). Regularization : Ridge regression and the LASSO [Lecture notes]. Statistics 305 : Autumn Quarter 2006/2007, Stanford University. Retrieved from

[6] Rosipal, R., & Krämer, N. (s.d.). Overview and recent advances in partial least squares. Austrian Research Institute for Artificial Intelligence & TU Berlin.

[7] Saporta, G. (2006). Probabilités, analyse des données et statistique (2e éd. rev. et augm.). Éditions Technip.

[8] Hastie, T., Tibshirani, R., & Wainwright, M. (2015). Statistical learning with sparsity : The lasso and generalizations. CRC Press.

ملخص

تهدف هذه المذكرة إلى تقديم إطار منهجي متكامل لتقدير نماذج الانحدار غير الخطي باستخدام خوارزميات الشبكات العصبية في إطار *R* البرمجي، مع تطبيق عملي على بيانات العقارات. اعتمد البحث على مقاربة ثلاثية الأبعاد: نظرية (استعراض شامل للدراسات السابقة حول نماذج الانحدار غير الخطي وتطبيقات الشبكات العصبية في إطار *R* البرمجي)، منهجية (تصميم أنظمة التقدير)، وتطبيقية (تنفيذ النماذج ومقارنة أدائها).

أظهرت النتائج تفوق الشبكات العصبية*(Neural Net=3,98)* على نماذج الانحدار التقليدية *(MCO : 4,79 et Lasso : 4,52)*، خاصة في معالجة العلاقات غير الخطية. غير أنها تفقد من دقتها عندما تتغير بنية البيانات، مما يستدعي البحث عن بدائل أكثر ملاءمة.

Résumé

Ce mémoire vise à proposer un cadre méthodologique intégré pour l'estimation des modèles de régression non linéaire à l'aide des algorithmes de réseaux de neurones dans l'environnement R, avec une application pratique aux données immobilières. La recherche repose sur une approche tridimensionnelle : théorique (revue exhaustive des travaux antérieurs sur les modèles de régression non linéaire et les applications des réseaux de neurones sous R), méthodologique (conception des systèmes d'estimation), et appliquée (implémentation des modèles et comparaison de leur performance).

Les résultats ont montré la supériorité des réseaux de neurones (Neural Net = 3,98) par rapport aux modèles de régression classiques (MCO : 4,79 ; Lasso : 4,52), notamment dans le traitement des relations non linéaires. Cependant, leur précision diminue lorsque la structure des données change, ce qui appelle à rechercher des alternatives plus adaptées.

Abstract

This thesis aims to provide an integrated methodological framework for estimating nonlinear regression models using neural network algorithms within the R environment, with a practical application to real estate data. The research adopts a three-dimensional approach: theoretical (a comprehensive review of previous studies on nonlinear regression models and neural network applications in R), methodological (designing estimation systems), and practical (implementing models and comparing their performance).

The results showed the superiority of neural networks (Neural Net = 3.98) over traditional regression models (OLS: 4.79, Lasso: 4.52), particularly in handling nonlinear relationships. However, their accuracy decreases when the data structure changes, highlighting the need to explore more suitable alternatives.