

UNIVERSITE KASDI MERBAH OUARGLA

Faculté des Nouvelles Technologies de l'Information et de la Communication

Département d'Informatique et des Technologies de l'Information



**Mémoire Master Professionnel**

**Domaine :** Informatique et Technologie de l'Information

**Filière :** Informatique

**Spécialité :** industriel

**Présenté par :**

Faiza Boukhelkhal & Rihana kennouna

**Thème :**

## **Évaluation de la qualité des images de contenu d'écran par une méthode de régression**

Soutenance fermée

Le 17/ 06/ 2023

Devant le jury

<b>Président</b>	<b>dr.Bekkari foued</b>	<b>UKM Ouargla</b>
<b>Encadreur</b>	<b>dr. Merzougui Naima.</b>	<b>UKM Ouargla</b>
<b>Examineur</b>	<b>dr.Amrane leila</b>	<b>UKM Ouargla</b>

**Année universitaire 2022/2023**

# Remerciement

*Tout d'abord, nous voudrions remercier "ALLAH" Tout-Puissant, qui nous a donné la force, la patience et la volonté pour faire cet humble travail.*

*Nous profitons cet mémoire de fin d'étude pour adresser nos remerciements à tous ceux qui ont participé dans ce travail*

*Nous tenons à remercier nos chers parents pour ces encouragements.*

*Nous tenons à exprimer nos plus vifs remerciements à notre promoteur,*

*Madame dr. Merzougui naima,, pour sa disponibilité, ses précieux conseils et ses encouragements*

*Nous remercions également les membres du jury pour l'intérêt.*

*Enfin, nous exprimons nos remerciements à toutes les personnes qui ont contribué d'une manière ou d'une autre à la réalisation de cet travail.*

# Dédicace



A ma mère en témoignage de ses sacrifices et ses soutiens

A mon père pour tous ses soutiens

Ames sœurs et mes frères

Ames deux grandes familles BOUKHELKHAL et CHABBIA

Ames amis et mes collègues

Je dédié ce modeste travail.

**FAIZA**

A ma mère en témoignage de ses sacrifices et ses soutiens

A mon père pour tous ses soutiens

Ames sœurs et mes frères

Ames deux grandes familles KENNOUNA et DEBBA

Ames amis et mes collègues

Je dédié ce modeste travail.

**RIHANA**



## Résumé

Les images jouent un rôle crucial dans de nombreuses applications dans divers domaines. Cependant, il est important d'évaluer la qualité car de multiples déformations peuvent se produire. Il existe certaines métriques, mais elles ne sont pas universellement efficaces pour toutes les images. Par conséquent, nous avons utilisé les résultats de certaines de ces mesures pour toutes les images de référence dans la base de données SCID comme données d'apprentissage pour la régression linéaire. Cette approche nous a permis de tirer parti des caractéristiques de ces métriques pour évaluer la qualité des images de manière générale. Les résultats obtenus avec à notre approche sur la base SCID montrent d'excellentes performances et une corrélation très satisfaisante avec les évaluations subjectives.

**Mots clés :** Image de contenu d'écran, Qualité d'image, Évaluation objective, Régression linéaire, multiple.

## Summary

Images play a crucial role in many applications across various domains. However, it is important to assess their quality as multiple distortions can occur. While there are some metrics available, they may not be universally effective for all images. Therefore, we utilized the results of some of these measures for all reference images in the SCID database as training data for linear regression. This approach allowed us to leverage the features of these metrics to evaluate image quality in a general sense. The results obtained using our approach on the SCID database demonstrate excellent performance and a highly satisfactory correlation with subjective evaluations.

**Keywords:** Screen Content Image, Image Quality, Objective Evaluation, Linear Regression multiple .

## ملخص

تلعب الصور دورًا حاسمًا في العديد من التطبيقات في مجالات مختلفة. ومع ذلك ، من الأهمية بمكان تقييم جودة الصور نظرًا لاحتمالية حدوث تشوهات متعددة فيها. هناك بعض المقاييس المستخدمة لتقييم جودة الصور ، ولكنها ليست فعالة بشكل عالمي لجميع الصور. وبالتالي ، قمنا باستخدام نتائج بعض هذه المقاييس لجميع الصور المرجعية في قاعدة بيانات كبيانات تعلم لتطبيق نموذج الانحدار الخطي. تمكننا هذه الطريقة من استغلال خصائص هذه المقاييس لتقييم جودة الصور بشكل عام. أظهرت النتائج التي تم الحصول عليها باستخدام هذا النهج على قاعدة بيانات أداءً ممتازًا وارتباطًا جيدًا مع التقييمات الشخصي

**الكلمات الرئيسية:** صورة شاشة المحتوى ، جودة الصورة ، تقييم موضوعي ، انحدار خطي المتعدد

## Table de matière

Introduction générale.....	11
1 Chapitre 01 : Qualité des images de contenu d'écran.....	2
1.1 Introduction .....	2
1.2 Définition générale d'une image .....	2
1.2.1 Définition d'une image numérique .....	3
1.2.2 Type d'image numérique .....	3
1.2.3 Les caractéristiques d'une image numérique .....	4
1.3 Image de contenu d'écran (SCI : Screen Content Image).....	7
1.3.1 La différence entre une image naturelle et une image de contenu d'écran.....	8
1.3.2 Définition qualité d'image contenue d'écran.....	8
1.3.3 Les bases d'image de contenu d'écran.....	9
1.3.4 Les types de distorsion d'image contenue d'écran .....	11
1.4 Méthodes d'évaluation de qualité d'image .....	17
1.4.1 Evaluation subjective .....	17
1.4.1.1 Distance d'observation : .....	17
1.4.1.2 Conditions de visualisation.....	18
1.4.1.3 Ecran.....	18
1.4.1.4 Le choix des images .....	18
1.4.1.5 Facteurs psychologiques .....	18
1.4.1.6 Matériel.....	18
1.4.1.7 Protocol.....	19
1.4.2 Evaluation objective.....	19
1.4.2.1 Les métriques sans référence .....	19
1.4.2.2 Les métriques avec référence réduite .....	19
1.4.2.3 Les métriques avec référence complet.....	19
1.5 Conclusion.....	23
2 Chapitre 02 : Méthodes des régressions .....	24

2.1	Introduction .....	24
2.2	Apprentissage automatique .....	24
2.2.1	Définition .....	24
2.2.2	Les types apprentissage automatique .....	24
2.3	Méthodes des régressions .....	27
2.3.1	Régression linéaire .....	27
2.3.1.1	Historique et origine de la régression .....	27
2.3.1.2	L'objectif de la régression linéaire .....	27
2.3.1.3	La régression linéaire simple .....	27
2.3.1.4	La Régression linéaire multiple .....	29
2.3.1.5	Régression Ridge .....	40
2.3.1.6	Régression lasso .....	41
2.3.1.7	Machine à vecteurs de support .....	41
2.3.1.8	Les avantage et les limites de régression linéaire .....	42
2.4	Conclusion.....	43
3	Chapitre 03 : Résultats Expérimentaux .....	44
3.1	Introduction .....	44
3.2	Les outils utilisés .....	44
3.2.1	Le matériel .....	44
3.2.2	Les logiciels .....	44
3.2.3	Bibliothèque .....	45
3.3	Bases d'image utilisée .....	46
3.4	Approche Proposée.....	46
3.5	Evaluation des résultats .....	47
3.6	L'interface et son contenu .....	50
3.7	Conclusion.....	52
	Conclusion générale .....	53
	Références bibliographique.....	54

## Table des figures

Figure 1.1 image (photographe) .....	2
Figure 1.2 Image numérique .....	3
Figure 1.3 Image vectorielle.....	3
Figure 1.4 Image matricielle .....	4
Figure 1.5 Image numérique (pixel).....	5
Figure 1.6 Dimension d'image numérique.....	5
Figure 1.7 Image et l'histogramme .....	6
Figure 1.8 Image avec texture .....	7
Figure 1.9 Exemple d'images naturelles par rapport aux images de contenu d'écran720 .....	8
Figure 1.10 Images de référence de la base SCID .....	10
Figure 1.11 Images de référence de la base SIQAD .....	11
Figure 1.12 le bruit gaussien .....	12
Figure 1.13 Flou gaussien .....	12
Figure 1.14 Flou de mouvement(MB) .....	13
Figure 1.15 Changement de contraste (CC) .....	14
Figure 1.16 Compression JPEG .....	15
Figure 1.17 Compression JPEG2000 .....	15
Figure 1.18 Changement de saturation de couleur (CSC).....	16
Figure 1.19 Compression de contenu d'écran HEVC (HEVC-SCC) .....	16
Figure 1.20 La quantification des couleurs avec le tramage (CQD) .....	17
Figure 2.1 Machines à vecteurs de support .....	42
Figure 3.3 Interface d'évaluation de qualité d'image contenue d'écran .....	50
Figure 3.4 Image originale et image déformée.....	51
Figure 3.5 Evaluation d'image par les différentes méthodes .....	51

---

**Liste des tableaux**

Tableau 1 Les donnés.....	37
Tableau 2.2 le résultat de solution.....	39
Tableau 3.1 évaluation par les coefficients de corrélation .....	50

---

## Liste des abréviations

**SCI** : Screen Content Image

**NI** : Image naturelle

**SCID**: Screen Content Image quality Database

**GB**: bruit gaussien

**GN**: flou gaussien

**MB**: flou de mouvement

**CC**: changement de contraste

**JPEG**: Joint Photographique Experts Group

**CSC**: changement de saturation des couleurs

**CQD**: quantification des couleurs avec tramage

**MOS** : Mean Opinion Score

**SIQAD**: Screen Image Quality Assessment Database

**SQMS**: Saliency-guided Quality Measure of SCIs

**GSS**: Gradient Similarity for SCI

**ESIM**: Edge SIMilarity

**GFM**: Gabor Feature-based Model

**SVQI**: Structural Variation based Quality Index

**SVM** : la machine à support vectoriel (Support Vector Machine).

**SCIQA-RL**: Screen Content Image Quality Assessment based Regression Linear.

---

## Introduction générale

Aujourd'hui, les images de contenu d'écran (SCI : Screen Content Image) sont devenues assez courantes dans notre vie quotidienne avec le développement rapide du multimédia et des réseaux sociaux. De nombreuses applications grand public, telles que Facebook, Twitter, le contrôle à distance et plus encore, impliquent des images de contenu d'écran généralisées par ordinateur.

Lors de l'acquisition, du traitement, de la compression, du stockage, de la transmission et de la reproduction, les images numériques peuvent introduire divers types de distorsions, et la qualité visuelle des images s'en trouve dégradée. Par conséquent, l'évaluation de la qualité d'image joue un rôle très important dans la communauté de traitement d'image.

Dans la littérature, différentes approches existent pour évaluer la qualité d'une image, à savoir les méthodes subjectives et les méthodes objectives. Les méthodes subjectives, bien qu'étant les plus fiables, impliquent l'évaluation par des observateurs humains, ce qui les rend coûteuses et chronophages. Par conséquent, il est nécessaire de développer des méthodes objectives permettant d'évaluer automatiquement la qualité visuelle et qui soit rapide et moins coûteuse.

De nombreuses métriques objectives ont été proposées, mais chacune d'entre elles est dédiée à certains types de dégradations spécifiques. Par conséquent, les chercheurs s'efforcent de trouver une métrique globale qui offre les meilleurs résultats en corrélation avec l'évaluation subjective. Dans ce contexte, nous proposons une approche combinant les métriques les plus performantes afin d'obtenir une métrique universelle adaptée à tous les types de dégradations.

Dans le cadre de notre projet, nous avons choisi d'utiliser la régression linéaire pour combiner ces métriques en raison de sa simplicité et de son efficacité. Notre mémoire est donc structurée en trois chapitres :

Le premier chapitre présente une vue d'ensemble sur les images et plus particulièrement sur les images de contenu d'écran, ainsi que les différents types de distorsions. Nous abordons également les bases des images spécifiques à ce type d'image, ainsi que les différentes métriques développées pour évaluer leurs qualités.

Le deuxième chapitre se concentre sur la définition et les types d'apprentissage automatique, ainsi que quelques méthodes de régression, en détaillant plus particulièrement l'algorithme de régression linéaire utilisé.

**Qualité des images de contenu  
d'écran**

# 1 Chapitre 01 : Qualité des images de contenu d'écran

## 1.1 Introduction

Avec le développement rapide de la technologie informatique et la popularité des appareils électroniques, les images de contenu d'écran (**SCI :Screen Content Image**) ont reçu beaucoup d'attention de la part des chercheurs en tant que principaux signaux générés par ordinateur. La qualité visuelle des SCIs a une influence sur les interférences externes lors de la compression, de la transmission, de l'affichage, ..... etc ce qui entraîne en outre une mauvaise qualité d'image. Par conséquent, il est nécessaire d'évaluer la qualité des SCIs afin d'assurer l'efficacité et la précision des systèmes de traitement d'image.

Dans ce chapitre nous présentons une observation générale sur l'image et image contenu d'écran et les différents types de distorsion, ensuite nous parlons sur les bases d'images spécifiées pour ce type d'image et les différentes métriques développées pour évaluer les SCIs

## 1.2 Définition générale d'une image

Une image peut être définie comme une représentation visuelle d'un objet ou d'une scène, qui peut être créée par des moyens tels que la peinture, la sculpture, le dessin, la photographie, le cinéma, etc. Elle peut également être considérée comme une structure organisée d'informations qui, une fois affichée sur un écran, est interprétée par l'œil humain. Cela peut être représenté sous la forme d'une fonction  $I(x, y)$ , où  $x$  et  $y$  représentent les coordonnées spatiales d'un point de l'image, et  $I$  représente l'intensité de la couleur et de la lumière. Cependant, cette représentation continue ne peut pas être traitée directement par une machine, et nécessite donc une numérisation pour être exploitable. [2]



Figure 1.1 image (photographe)

### 1.2.1 Définition d'une image numérique

Une **image** est une représentation graphique ou visuelle qui vise à décrire un objet, une personne, un concept ou une idée.

Le terme "**numérique**" fait référence aux techniques qui permettent de produire, stocker et traiter des informations en utilisant des codes binaires (sous forme de chiffres 0 et 1) sur un ordinateur ou un appareil électronique. [4]

**L'image numérique:** Se représente sous la forme d'un tableau à deux dimensions contenant des valeurs entières. [4]

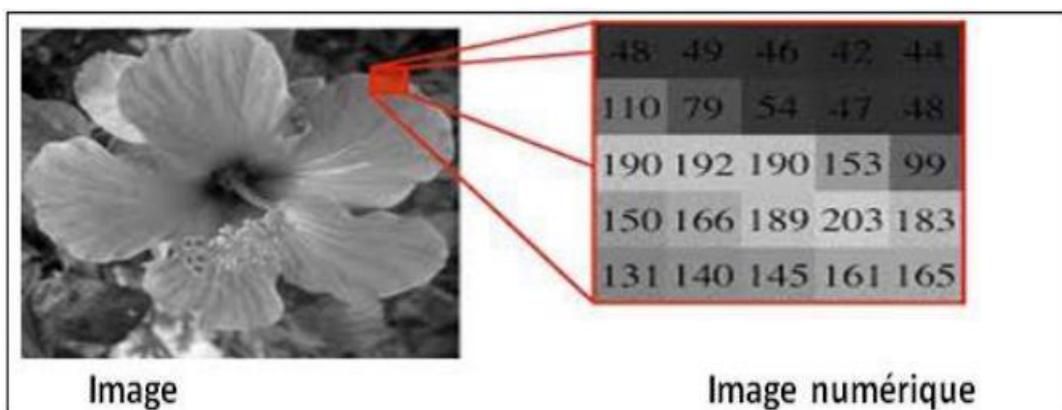


Figure 1.2 Image numérique [4]

### 1.2.2 Type d'image numérique

Deux types d'images numériques

#### Image Vectorielle

Formée de lignes calculées de manière géométrique. Lors d'un zoom avant ou arrière, la forme est recalculée en fonction de notre position sans perdre de qualité. [34]



Figure 1.3 Image vectorielle [34]

## Image Matricielle (ou tramée)

Formée d'une grille composée de points carrés individuels nommés pixels. Plus on zoom, plus les pixels deviennent apparents.

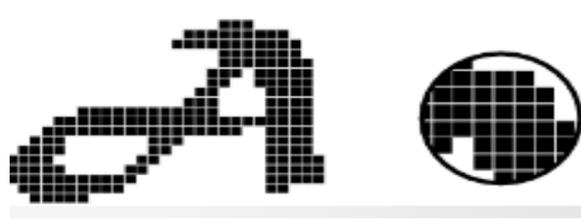


Figure 1.4 Image matricielle [34]

### 1.2.3 Les caractéristiques d'une image numérique

L'image est un ensemble structuré d'informations caractérisé par les paramètres suivants:

#### ➤ Pixel

L'Expression "Picture Elements" peut être contractée en "Pixélisation", qui désigne le processus de division d'une image en une grille de pixels, chacun représentant une valeur numérique de couleur et d'intensité lumineuse. Le pixel est donc l'unité de base de l'image, qui peut être manipulée par les logiciels et les matériels d'affichage pour créer, modifier et afficher des images numériques.

En d'autres termes, la pixellisation est la transformation d'une image continue en une image discrète, composée de pixels individuels. Cette technique est utilisée dans de nombreuses applications, telles que la photographie numérique, la vidéo, la conception graphique, les jeux vidéo et la réalité virtuelle.

Ainsi, le pixel est l'élément clé de la pixellisation, permettant la représentation numérique de l'image et sa manipulation par les ordinateurs et les logiciels.[4]

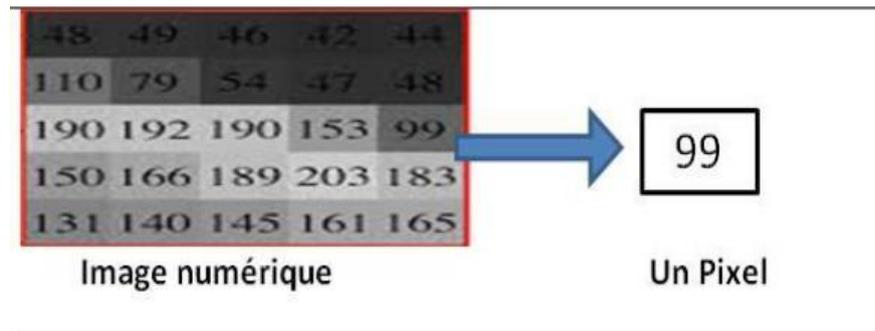


Figure 1.5 Image numérique (pixel) [4]

Est déterminée par sa taille, c'est-à-dire le nombre de points ou de pixels qui la composent. Elle se mesure à la fois en hauteur (axe vertical) et en largeur (axe horizontal). Ainsi, une image qui mesure 640 pixels de large sur 480 pixels de haut aura une définition de 640x480 pixels. [4]

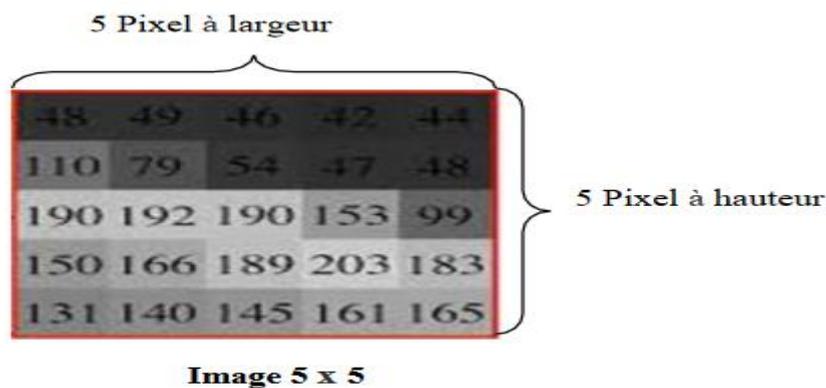


Figure 1.6 Dimension d'image numérique [4]

### ➤ La résolution

D'une image est mesurée en dpi (dots per inch) ou en ppp (points par pouce), qui correspondent respectivement au nombre de points ou de pixels par unité de longueur. Ce paramètre est généralement défini lors de la numérisation de l'image et dépend des caractéristiques du matériel utilisé. Si la résolution est augmentée, cela peut entraîner des temps de visualisation et d'impression plus longs, ainsi qu'une taille de fichier plus importante contenant l'image. [4]

### ➤ L'histogramme

Est un graphique statistique qui permet de visualiser la distribution des intensités de pixels dans une image, c'est-à-dire le nombre de pixels pour chaque intensité lumineuse. Il

représente conventionnellement le niveau d'intensité en abscisse, allant du plus foncé (à gauche) au plus clair (à droite). L'ajustement de l'histogramme est souvent utilisé pour réduire l'erreur de quantification, comparer deux images prises sous différents éclairages ou mesurer certaines propriétés sur une image. [30]

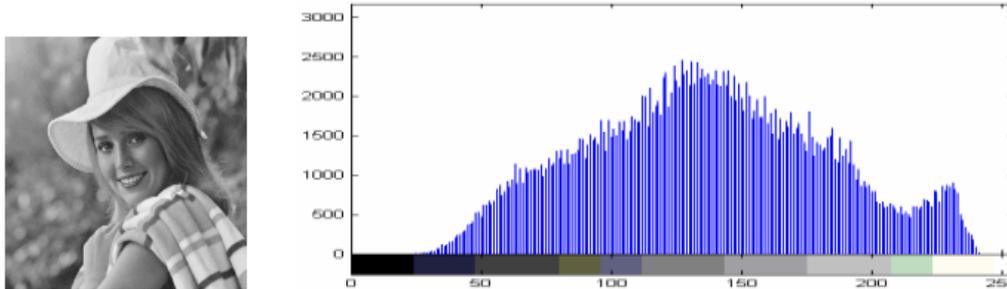


Figure 1.7 Image et l'histogramme [31]

#### ➤ La luminance

D'une image représente le niveau de luminosité des différents points qui la composent. Elle est également définie comme le rapport entre l'intensité lumineuse d'une surface et sa surface apparente, pour un observateur distant. Le terme "luminance" est souvent utilisé pour remplacer le terme "brillance", qui fait référence à l'éclat ou à la réflexion de la lumière sur un objet. [4]

#### ➤ Le contraste

Dans une image correspond à la différence notable entre les zones claires et sombres de cette image. Il est déterminé par les niveaux de luminance de deux zones distinctes de l'image. Si  $L_1$  et  $L_2$  représentent respectivement les niveaux de luminosité de deux zones adjacentes  $A_1$  et  $A_2$  d'une image, le contraste  $C$  peut être calculé en utilisant le rapport suivant : [4]

$$C = \frac{L_1 - L_2}{L_1 + L_2} \quad (1.1)$$

#### ➤ Le poids ou la taille

D'une image dépend de deux paramètres, à savoir les dimensions de l'image et sa profondeur de bits. Pour calculer le poids d'une image, il suffit de multiplier ces deux valeurs. Par exemple, pour une image de dimensions 640x480 en couleurs vraies :

Nombre de pixels (dimensions) :  $640 \times 480 = 307200$  pixels

Profondeur de chaque pixel : 24 bits = 3 octets

Le poids de l'image est donc égal à :  $307200 \times 3 = 921600$  octets. [4]

### ➤ Contours et textures

Font référence à des caractéristiques visuelles des images. Les contours sont les lignes qui délimitent les objets dans l'image, ou les limites entre deux pixels dont les niveaux de gris sont sensiblement différents. En revanche, les textures décrivent la structure des surfaces de l'image. L'extraction de contours consiste à identifier les points de l'image qui séparent deux textures différentes. [4]

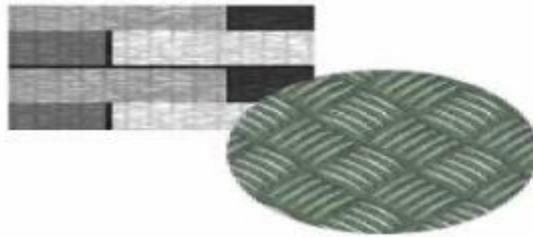


Figure 1.8 Image avec texture [4]

### 1.3 Image de contenu d'écran (SCI : Screen Content Image)

Un écran est un dispositif électronique qui affiche des images, des vidéos ou du texte à partir d'un signal électronique. Il se compose d'une surface plane qui peut être fabriquée en différents matériaux tels que le verre, le plastique ou les cristaux liquides, et d'un système électronique qui convertit le signal en images visibles à l'écran. Les écrans sont largement utilisés dans les ordinateurs, les télévisions, les smartphones, les tablettes et autres dispositifs électroniques pour permettre aux utilisateurs de visualiser des informations et de communiquer visuellement.[5]

De nos jours, l'utilisation générale des réseaux sociaux et du multimédia a conduit à la création de diverses applications, notamment des actualités et des publicités en ligne, des cours en ligne, des brochures électroniques, des plateformes telles que Facebook et Twitter, etc. Les images de contenu d'écran (SCI) sont couramment utilisées dans ces applications, qui peuvent inclure des images naturelles, du texte, des graphiques, des cartes et des logos. Par conséquent, les SCI sont devenues très populaires dans notre vie quotidienne. En outre, en

raison de la forte demande pour ces services riches en graphiques, l'évaluation de la qualité de SCI est devenue un sujet brûlant ces derniers temps.[1]

### 1.3.1 La différence entre une image naturelle et une image de contenu d'écran

Des études ont montré que les images de contenu d'écran (SCI) ont plusieurs caractéristiques distinctes des images naturelles (NI). Les NI sont caractérisées par des variations de couleurs riches, des bords lisses et un contenu de texture complexe avec des lignes épaisses. En revanche, les SCI ont généralement des lignes plus fines, des bords nets, des variations de couleurs limitées et des formes simples. Ces différences rendent l'évaluation de la qualité des SCI plus difficile, car les théories de conception développées pour les images de scènes naturelles sont moins fiables et ne sont pas directement applicables aux SCI[1]

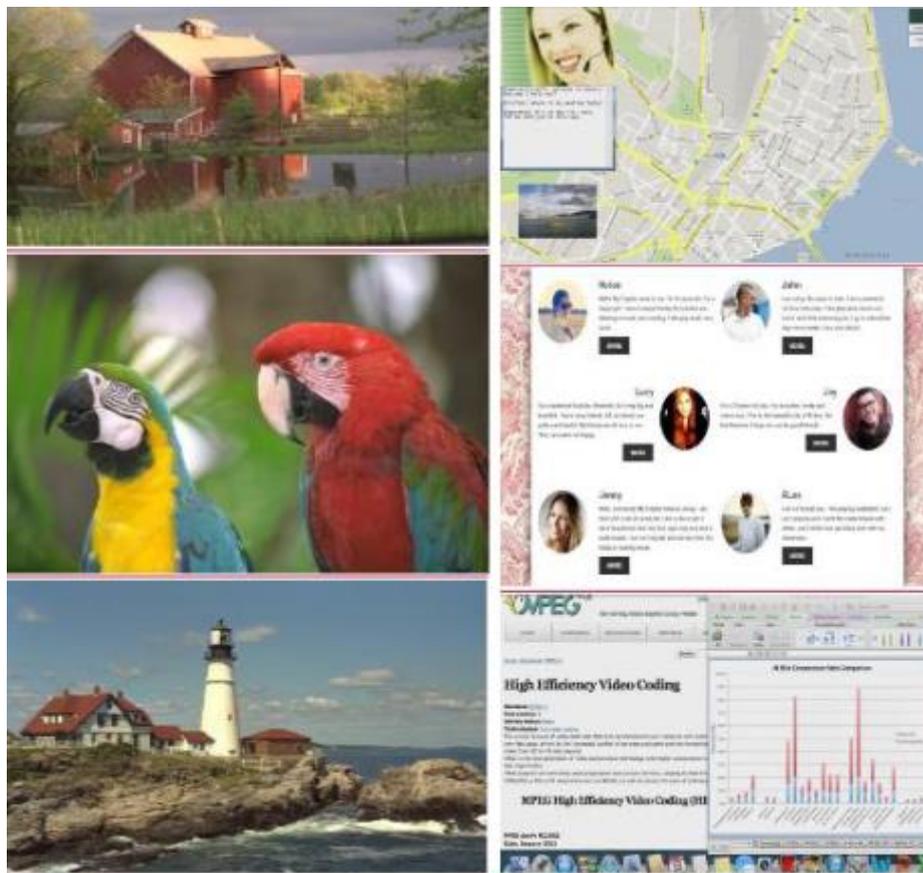


Figure 1.9 Exemple d'images naturelles par rapport aux images de contenu d'écran[7][20]

### 1.3.2 Définition qualité d'image contenu d'écran

De nos jours, l'évaluation de la qualité d'image est indispensable dans diverses applications de communication multimédia. Les images subissent différents traitements de codage et de compression, et leur qualité est altérée lors de la transmission des données multimédias à

travers les réseaux de communication. Cela conduit à des distorsions dans l'image qui nuisent à sa qualité. [3]

En général, la qualité d'image contenu d'écran dépend de la résolution et de l'équilibre des couleurs, qui est souvent appelé contraste. La résolution fait référence à la quantité de détails présents dans une image. En règle générale, plus il y a de détails dans une image, plus sa résolution est élevée

### 1.3.3 Les bases d'image de contenu d'écran

Les bases d'images disponibles pour la validation des méthodes de qualité d'images pour les images de contenu d'écran sont peu nombreuses dans la littérature. Parmi celles-ci :

➤ **La base SCID** (Screen Content Image quality Database)

Est une collection d'images de contenu d'écran destinée à l'évaluation de la qualité d'image. Elle se compose de 40 images de référence et de 1800 images dégradées par 9 types de distorsions différents, à cinq niveaux de perturbation. Les types de distorsion inclus dans cette base de données sont : le bruit gaussien (GB), le flou gaussien (GN), le flou de mouvement (MB), le changement de contraste (CC), la compression JPEG (JPEG), la compression JPEG2000 (J2K), le changement de saturation des couleurs (CSC), la quantification des couleurs avec tramage (CQD) et le codage de contenu d'écran à haute efficacité (HEVC-SCC). Les images ont une résolution de 1280×720 pixels. Les évaluations subjectives, mesurées en termes de scores MOS (Mean Opinion Score), ont été obtenues en utilisant une méthode d'échelle de dégradation à double stimulus[7]. La figure 1.10 présente les images de référence de cette base.[7]

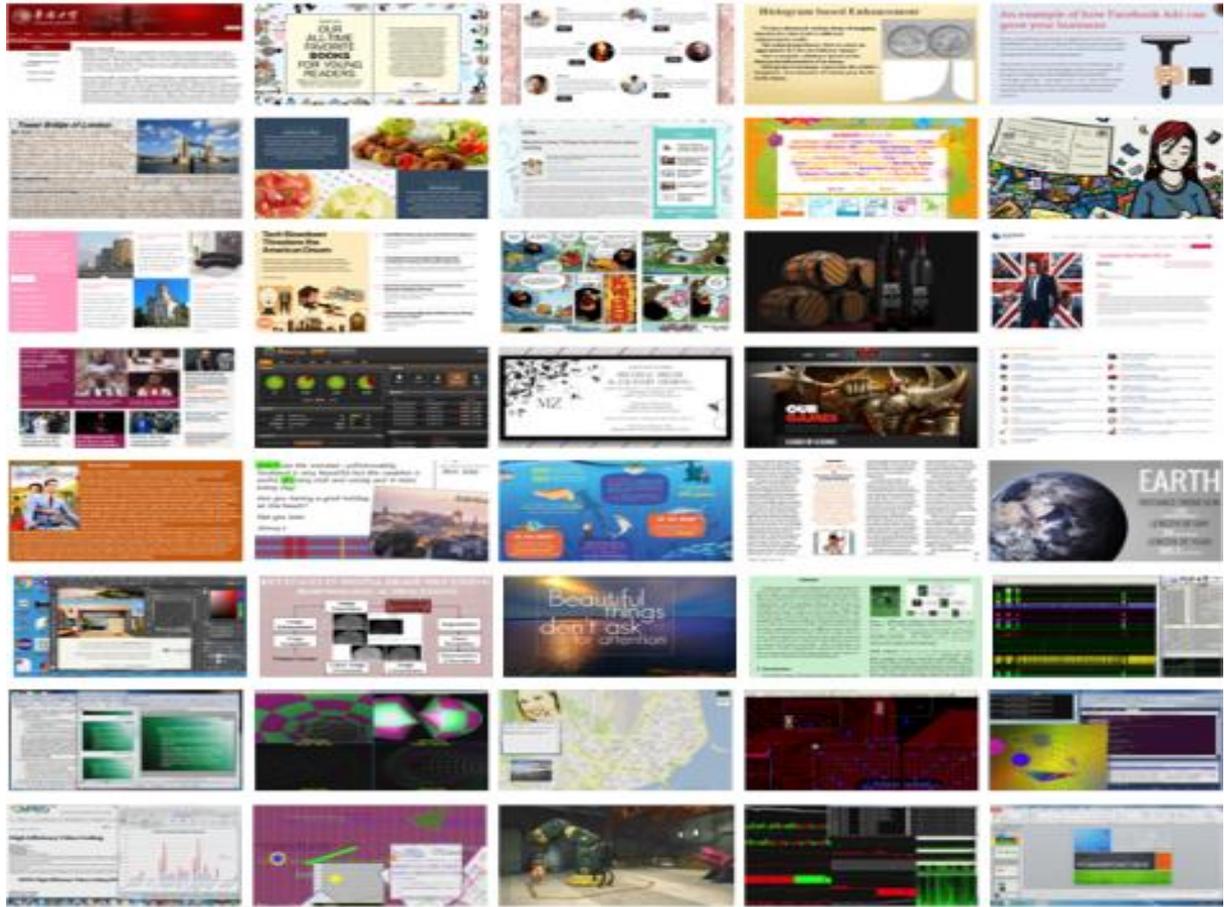


Figure 1.10 Images de référence de la base SCID [7]

➤ **La base SIQAD** (Screen Image Quality Assessment Database)

La base de données SIQAD (Screen Image Quality Assessment Database) contient jusqu'à 980 images de qualité d'image (SCI) altérées en corrompant 20 sources avec sept types de distorsion à sept niveaux différents. Les 20 images SCI de référence sont ensuite recadrées pour qu'elles puissent être affichées correctement sur les écrans d'ordinateur pendant l'expérience subjective. Chaque image d'origine subit les sept types de distorsion, qui incluent le bruit gaussien, le flou gaussien, le flou de mouvement, le changement de contraste, la compression JPEG, la compression JPEG2000 et le codage basé sur la segmentation de couche (LSC). Pour l'évaluation subjective, une échelle discrète de 11 points est utilisée, allant du pire score possible de "0" au meilleur score possible de "10", avec des intervalles de "1", conformément à la recommandation UIT-R BT.500-13 pour l'utilisation de la méthode de stimulus unique (SS)[8]. La figure 1.11 présente les images de référence de cette base. [8]

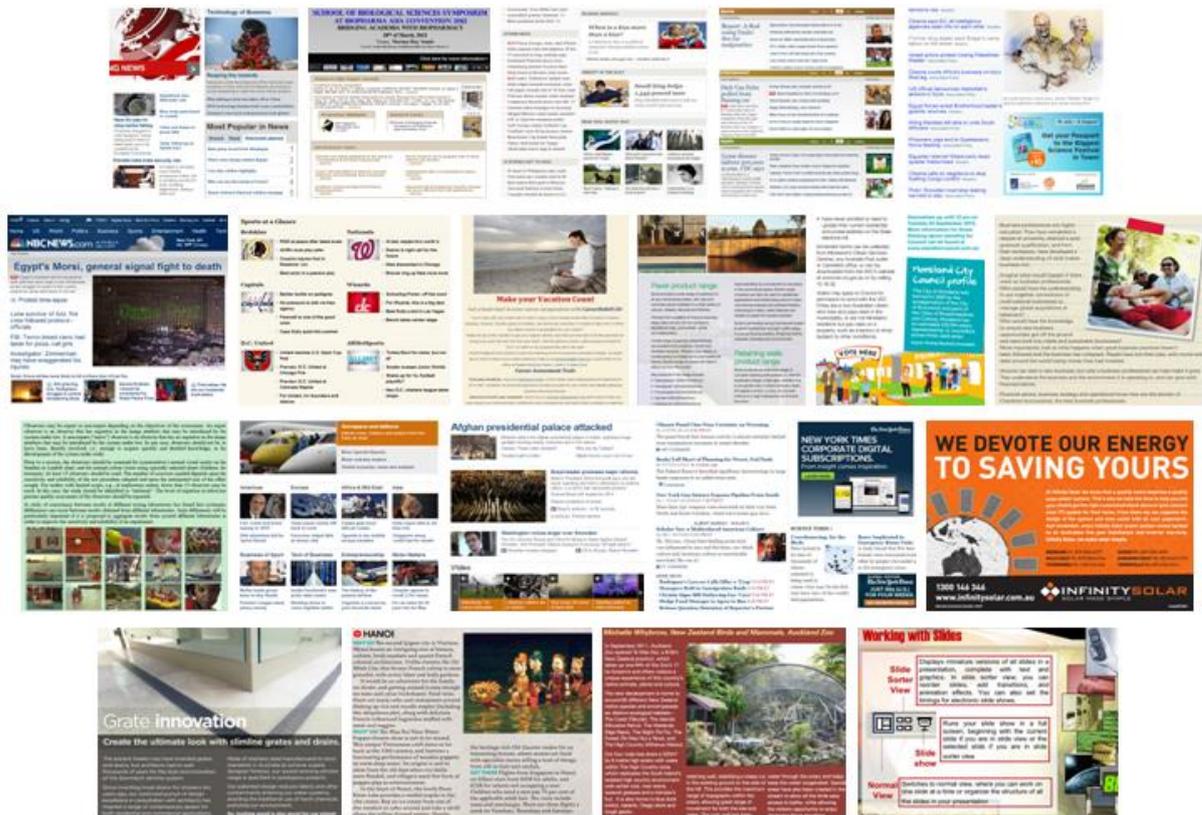


Figure 1.11 Images de référence de la base SIQAD [8]

### 1.3.4 Les types de distorsion d'image contenu d'écran

Les SCIs déformées sont générées en appliquant diverses opérations d'image à chaque SCI de référence, individuellement. Les opérations d'image pour générer 9 types de distorsion avec 5 niveaux de dégradation (allant du niveau imperceptible au niveau hautement ennuyeux) sont introduites comme suit :

#### ➤ Bruit gaussien (GN)

Le bruit gaussien, également connu sous le nom de bruit statistique de distribution normale ou gaussienne, est généré en ajoutant une fonction gaussienne aléatoire à une fonction image. Ce type de bruit est parfois appelé bruit électronique, car il se produit souvent dans les amplificateurs ou les détecteurs. Il est causé par la vibration thermique des atomes et la nature discrète du rayonnement des objets chauds.

Le bruit d'image correspond à une fluctuation aléatoire de la luminosité ou des informations de couleur dans les images capturées, résultant de sources externes qui dégradent le signal d'image. Les images contenant du bruit multiplicatif se caractérisent par une

augmentation du bruit proportionnelle à l'intensité lumineuse. Toutefois, le bruit est principalement additif.



Image de référence

Image dégradée

Figure 1.12 le bruit gaussien[7]

➤ **Flou gaussien (GB)**

Le flou gaussien est une technique couramment utilisée dans le traitement d'image et les applications informatiques visuelles pour créer un flou artistique. Il s'agit d'un filtre passe-bas qui lisse l'image en prenant la moyenne des valeurs de pixel dans un voisinage autour de chaque pixel. La quantité de flou est contrôlée par la taille du voisinage, et elle permet généralement de réduire le bruit de l'image et de supprimer les détails. L'effet visuel produit par cette technique est un flou doux qui donne l'impression que l'image est projetée à travers un écran transparent. [15]



Image de référence

Image dégradée

Figure 1.13 Flou gaussien [7]

➤ **Flou de mouvement (MB)**

Le flou de mouvement est un effet visuel dans les photographies ou les séquences d'images, telles que les films ou les animations, qui donnent l'impression de traînées derrière les objets en mouvement. Cela se produit lorsqu'il y a un changement dans l'image pendant l'exposition en raison d'un mouvement rapide ou d'une exposition prolongée. Étant donné que cet effet est causé par le mouvement relatif entre la caméra, les objets et la scène, il peut être manipulé en faisant pivoter la caméra pour suivre ces objets en mouvement. Dans ce cas, même avec des temps d'exposition prolongés, les objets en mouvement apparaîtront plus nets tandis que l'arrière-plan deviendra plus flou, ce qui donnera une impression de mouvement et de vitesse dans l'image résultante [16]



Image de référence

Image dégradée

Figure 1.14 Flou de mouvement(MB) [7]

➤ **Changement de contraste (CC)**

Le réglage de contraste, également connu sous le nom de modification de contraste, est une méthode d'édition d'images qui consiste à ajuster la différence de luminosité et d'obscurité entre les pixels adjacents d'une image. Le contraste est une mesure relative de la différence entre les zones claires et sombres de l'image, et il a un impact sur l'apparence générale de l'image. En ajustant le contraste, il est possible d'améliorer les détails et de rendre l'image plus ou moins nette. Augmenter le contraste d'une image rend les zones claires plus lumineuses et les zones sombres plus sombres, créant ainsi un aspect plus dynamique et dramatique. Cette technique est couramment utilisée en photographie pour créer des images percutantes ou pour rendre les détails plus visibles. La diminution du contraste peut créer une apparence plus douce et subtile, souvent utilisée dans la photographie artistique ou de style vintage. [17]

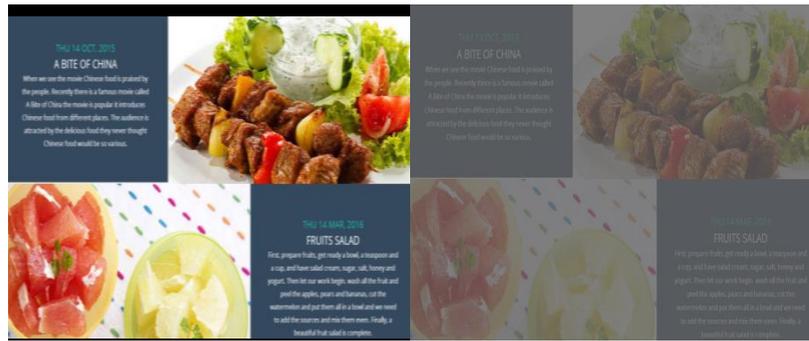


Image de référence

Image dégradée

Figure 1.15 Changement de contraste (CC) [7]

➤ **Compression JPEG**

Est une norme ISO/ITU-T très connue créée à la fin des années 1980. La norme jpeg est destinée aux applications de trames fixes en couleur complète. La norme JPEG est la norme de codage JPEG. Plusieurs modes sont définis pour le JPEG, notamment de base, sans perte, progressif et hiérarchique. Le mode le plus courant utilise la transformée en cosinus discrète, c'est le système de codage JPEG de base, il convient également à la plupart des applications de compression. Bien qu'il ait été développé pour des compressions faibles, JPEG est très utile pour la quantification et la compression de la DCT. La compression JPEG réduit la taille du fichier avec un minimum de dégradation de l'image en éliminant les informations les moins importantes. Mais il est considéré comme une technique de compression d'image avec perte, car l'image finale et l'image d'origine ne sont pas complètement identiques et en compression avec perte, les informations qui peuvent être perdues et manquées sont acceptables. La compression JPEG est effectuée en étapes séquentielles. [18]



Image de référence

Image dégradée

Figure 1.16 Compression JPEG[7]

➤ **Compression JPEG2000**

La norme JPEG 2000 se sert d'une transformation en ondelettes biorthogonales séparables pour décomposer l'image entière en sous-bandes de fréquences en utilisant une technique dyadique. Dans cette méthode, on utilise une ondelette de type Daubechies 9/7 pour la compression avec perte et une ondelette de LeGall 5/3 pour la compression sans perte. Les coefficients obtenus par la décomposition en ondelettes de LeGall sont des nombres rationnels, ce qui est nécessaire pour une reconstitution parfaite du signal original. Le choix de ces ondelettes n'est pas aléatoire, car ils remplissent plusieurs critères mathématiques permettant d'obtenir des résultats de qualité sur les images. Il est à noter que le choix des ondelettes dépend du type de signal à analyser. [19]

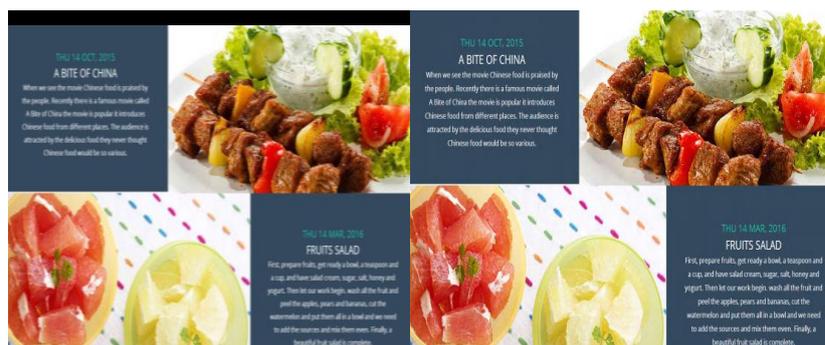


Image de référence

Image dégradée

Figure 1.17 Compression JPEG2000 [7]

➤ **Changement de saturation de couleur (CSC)**

La saturation d'une image est la mesure de la pureté et de l'intensité de ses couleurs. En ajustant la saturation, on peut rendre les couleurs plus vives et éclatantes ou plus douces et pastel. Une augmentation de la saturation peut intensifier les couleurs, tandis qu'une diminution peut produire un effet plus subtil et discret.[20]



Image de référence

Image dégradée

Figure 1.18 Changement de saturation de couleur (CSC) [7]

➤ **Compression de contenu d'écran HEVC (HEVC-SCC)**

Est un sujet chaud dans les applications de traitement multimédia et HEVC-SCC est capable d'atteindre un taux de compression élevé. HEVC-SCC est également utilisé pour générer les SCIs déformés. Les SCIs déformés correspondants avec la compression HEVC-SCC sont obtenus en effectuant l'encodeur HEVC-SCC avec une configuration standard, tous les paramètres Intra Main. Les paramètres de quantification sont définis entre 16 et 48.n [7] [8]



Image de référence

Image dégradée

Figure 1.19 Compression de contenu d'écran HEVC (HEVC-SCC) [7]

➤ **La quantification des couleurs avec le tramage (CQD)**

La technique de quantification des couleurs avec tramage (CQD) est utilisée pour réduire le nombre de couleurs dans une image tout en minimisant la perte de qualité visuelle. Cette technique fonctionne en attribuant à chaque pixel de l'image une couleur représentative à partir d'un ensemble plus petit de couleurs, puis en ajoutant un motif de bruit, ou tramage, pour simuler les couleurs manquantes. La quantification des couleurs est nécessaire lorsque l'image contient plus de couleurs qu'il n'est possible d'afficher ou d'imprimer. Par exemple, si une image est destinée à être affichée sur un écran couleur 8 bits, qui ne peut afficher que 256 couleurs, l'image doit être quantifiée à 256 couleurs ou moins. [21]



Image de référence

Image dégradée

Figure 1.20 La quantification des couleurs avec le tramage (CQD) [7]

## 1.4 Méthodes d'évaluation de qualité d'image

### 1.4.1 Evaluation subjective

L'évaluation subjective est considérée comme la méthode la plus fiable pour mesurer la qualité réelle. Elle implique que l'observateur humain juge la qualité des images présentées selon une grille d'évaluation à plusieurs niveaux d'appréciation et qu'une note subjective appelée MOS (Mean Opinion Score) est obtenue à la fin des tests. Cependant, il est important de faire attention à certains facteurs pouvant altérer les jugements des participants lors de la réalisation de ces tests. Ces facteurs sont énumérés ci-dessous:

#### 1.4.1.1 Distance d'observation :

La visibilité d'un stimulus dépend fortement de la distance d'observation. Il est recommandé de fixer cette distance entre 4 à 6 fois la hauteur de l'image de projection et de la maintenir tout au long du test. [6]

### 1.4.1.2 Conditions de visualisation

L'éclairage de la salle et la couleur de fond de l'environnement jouent également un rôle important. Un éclairage trop intense peut éblouir l'observateur et altérer sa perception. De même, la couleur de fond de la salle peut affecter l'apparence de certaines couleurs. Ainsi, pour une perception optimale des stimuli, il est important de prendre en compte ces éléments et de les adapter en conséquence. [6]

### 1.4.1.3 Ecran

Il est nécessaire de calibrer l'écran de façon à reproduire les couleurs souhaitées. Sans cette calibration, les couleurs affichées peuvent être différentes du stimulus d'origine. Il est important aussi de tenir compte de quelques artefacts liés à la technologie de l'écran utilisée [35]

### 1.4.1.4 Le choix des images

Un panel d'images de contenus visuels assez variés et le plus représentatif possible des scènes liées à l'application visée doit être utilisé. [6]

### 1.4.1.5 Facteurs psychologiques

Pour minimiser les effets liés à l'état psychologique de l'observateur lors de la réalisation de tests, il est important de prendre plusieurs mesures. Tout d'abord, il convient de débiter les tests par une séance d'initiation pour permettre à l'observateur de mieux appréhender le test. Ensuite, il est crucial d'expliquer clairement l'objectif du test et le protocole à respecter, sans influencer le jugement des participants. Enfin, il est préférable de mener de nombreux tests de courte durée (environ 10 minutes) et variés plutôt que d'imposer des séances longues (environ 30 minutes) et fatigantes, qui risquent de conduire l'observateur à un jugement rapide et erroné. Ces mesures permettent de minimiser les biais liés à l'état psychologique de l'observateur et d'obtenir des résultats plus fiables et pertinents. [7]

### 1.4.1.6 Matériel

Le processus d'évaluation est effectué sur des ordinateurs de bureau équipés d'un écran LED de 23 pouces, de 8 Go de RAM et d'un système d'exploitation Windows 64 bits dans des conditions d'éclairage normales [7]

#### **1.4.1.7 Protocol**

La norme ITU-R BT.500-13 spécifie plusieurs méthodes de test subjectif pour évaluer la qualité des images, qui peuvent être classées en stimulus simple ou double stimulus en fonction de la disponibilité de différents stimuli. L'approche de double stimulus est connue pour être plus fiable, et dans cette étude, la méthode d'échelle d'altération à double stimulus (DSIS) avec une échelle discrète de 5 catégories est utilisée. [6]

#### **1.4.2 Evaluation objective**

Ces dernières années, on observe une augmentation des recherches dans le domaine de l'évaluation de la qualité d'image contenu d'écran, en particulier dans le domaine de la mesure de qualité objective. Cette technique d'évaluation permet de mesurer automatiquement la qualité des images en prenant en compte la qualité subjective. Différents types de critères ont été développés à cet effet, et de nouvelles idées sont proposées pour améliorer les mesures objectives. Des modèles et des fonctions mathématiques sont définis pour les différentes méthodes de mesure de la qualité objective, permettant ainsi d'accéder automatiquement à la qualité de l'image contenue d'écran et de la noter selon l'échelle définie. En fonction de l'existence ou non de la référence, on distingue trois types de métriques objectives.

##### **1.4.2.1 Les métriques sans référence**

Lorsqu'il s'agit d'une dégradation spécifique, les mesures sans référence sont préférables car elles permettent d'estimer la qualité à partir de l'image dégradée seule. Cependant, il est généralement supposé que le type de dégradation présent dans l'image est connu.

##### **1.4.2.2 Les métriques avec référence réduite**

Les mesures à référence réduite ont été développées pour offrir une solution intermédiaire aux contraintes liées aux mesures avec et sans référence. Elles permettent de quantifier la qualité d'une image contenu d'écran en utilisant quelques attributs ou descripteurs de l'image originale, sans avoir besoin d'informations a priori sur le type de dégradation présent dans l'image. Bien que relativement accessibles dans un cadre applicatif, ces méthodes restent moins utilisées que les autres.

##### **1.4.2.3 Les métriques avec référence complet**

Cette approche implique une comparaison directe entre l'image dégradée et l'image de référence, ce qui nécessite la disponibilité d'une image de référence.

Plusieurs algorithmes ont été développés pour l'évaluation de la qualité d'image de contenu de l'écran (SCIQA), notamment GFM (Ni et al., 2018), GSS (Ni et al., 2016), SCDM\_new (Bae and Kim, 2016), SCQI\_new (Bae and Kim, 2016), SQMS (Gu et al., 2016a), SVQI (Gu et al., 2018) et ESIM (Ni et al., 2017). Bien que ces méthodes aient obtenu des résultats encourageants dans l'évaluation de la qualité des SCI, une brève description générale de ces méthodes est présentée ci-dessous : [1]

➤ **SQMS** (Saliency-guided Quality Measure of SCIs)

Cette métrique SQMS est développée en utilisant la carte de saillance  $M$  pour pondérer la carte de similarité  $GM$ . Il convient de noter que les éléments de valeur supérieure dans  $M$  sont plus similaires aux voisins et ont donc moins de saillance visuelle. Par conséquent, la saillance visuelle pour dériver la carte de pondération est calculée comme suit :

$$\mathbf{W}(\mathbf{r}) = \mathbf{1} - \mathbf{M}(\mathbf{r}) \quad (1.2)$$

Elle est utilisée pour prédire le score de qualité, et les pixels saillants sont mis en évidence. La carte SQMS\_MAP peut être obtenue par: [9]

$$SQMS_{MAP}(r_i, d_i) = \frac{G(r_i, d_i) \cdot W(r_i)}{\frac{1}{K} \sum_{i=1}^K W(r_i)} \quad (1.3)$$

Où  $k$  désigne le nombre total de pixels dans l'image.

Le score SQMS est obtenu en utilisant la moyenne globale

$$SQMS(r, d) = \frac{1}{K} \sum_{i=1}^K SQMS_{MAP}(r_i, d_i) \quad (1.4)$$

➤ **SCQI** (Structural Contrast-Quality Index)

Le contraste est une caractéristique perceptuelle de base d'une image qui varie considérablement sur l'image. Bae et al. [10] ont proposé l'indice de qualité de contraste structurel (SCQI) en adoptant l'indice de contraste structurel (SCI), qui peut estimer la complexité perceptive des motifs de texture d'image en tant que rapport de structure et d'intensité de contraste. Ici, nous décrivons brièvement le SCQI de manière indépendante

SCQI donne une valeur d'indice de qualité qui est calculée comme suit : [10]

$$SCQI = \sum \left[ \frac{1}{W} \sum_{i=1}^k w_i \odot SCQI_{Map} \right] \quad (1.5)$$

où  $K$  est le nombre d'éléments dans  $SCQI_{Map}$ ,  $W_i$  est le poids local,  $W$  est la somme de tous les poids, et  $SCQI_{Map}$  est la carte de similarité calculée par multiplication élémentaire de six cartes de similarité  $s_{mi}, i=1, \dots, 6$ .

➤ **GSS** (Gradient Similarity for SCI)

La magnitude de gradient est couramment utilisée pour évaluer la qualité perceptuelle des images naturelles, ce qui pourrait être considéré comme une partie complémentaire de la direction de gradient proposée. En se basant sur cette intuition, ils peuvent être conjointement utilisés pour décrire la dégradation de qualité perceptive des SCI. De manière similaire à la similarité de direction de gradient proposée, la mesure suivante a été proposée pour évaluer la similarité de magnitude de gradient (dénommée MS) entre les SCI de référence et déformés :

$$\mathbf{MS}(\mathbf{x}, \mathbf{y}) = \frac{2G_r(\mathbf{x}, \mathbf{y})G_d(\mathbf{x}, \mathbf{y}) + C_M}{G_r^2(\mathbf{x}, \mathbf{y}) + G_d^2(\mathbf{x}, \mathbf{y}) + C_M} \quad (1.6)$$

Où  $G_r$  et  $G_d$  sont les cartes de magnitude de gradient des SCI de référence et déformés respectivement,  $C$  est une petite constante positive pour assurer la stabilité numérique. Comme mentionné précédemment,  $d_s$  et  $M_s$  sont calculés pour décrire la similarité des SCI selon des perspectives différentes. Afin de décrire pleinement la similarité des SCI,  $d_s$  et  $M_s$  sont fusionnés ensemble comme suit:

$$\mathbf{GS}(\mathbf{x}, \mathbf{y}) = [\mathbf{DS}(\mathbf{x}, \mathbf{y})]^\alpha [\mathbf{MS}(\mathbf{x}, \mathbf{y})]^\beta \quad (1.7)$$

Où  $G_s$  est la carte de similarité de gradient fusionnée,  $\alpha \geq 0$  et  $\beta \geq 0$  sont deux paramètres utilisés pour ajuster l'importance relative de la direction de gradient proposée et de l'amplitude de gradient, respectivement. La carte de similarité de gradient fusionnée  $G_s$  est combinée pour générer l'indice de qualité GSS, qui indique la qualité perceptive de la SCI déformée : [11]

$$\mathbf{GSS} = \left( \frac{1}{N} \sum_{(\mathbf{x}, \mathbf{y}) \in \Omega} (\mathbf{GS}(\mathbf{x}, \mathbf{y}) - m_{GS})^2 \right)^2 \quad (1.8)$$

Où  $m_{GS}$  est la valeur moyenne de  $G_s$ . De même que pour DSS, plus le score GSS est élevé, plus la plage de distorsion est grande, et donc plus la qualité perceptive du SCI est faible

➤ **ESIM** (Edge SIMilarity)

Cette méthode d'évaluation de la qualité d'image basant sur trois attributs de bord saillants des SCI : le contraste des bords, la largeur des bords et la direction des bords.

Des facteurs de pondération simples et efficaces peuvent être conçus sur la base du champ de données existant si l'emplacement du pixel  $(x, y)$  du SCI d'origine ou déformé a entraîné une grande largeur de bordure  $w$  (que ce soit dans le SCI de référence ou le SCI déformé), cela signifie que le HVS sera assez sensible à cette position. Par conséquent,  $EWM_r$  et  $EWM_d$  sont les cartes de largeur de bordure des SCIs référence et avec distorsion, respectivement. La valeur maximale de largeur de bordure basée sur ces deux cartes peut être utilisée comme facteur de pondération; c'est-à-dire :

$$\mathbf{W}(x, y) = \max(\mathbf{EWM}_r, \mathbf{EWM}_d) \quad (1.9)$$

Par conséquent, le score IQA, appelé score de similarité de bordure (ESIM), peut être calculé "pooled" par la moyenne pondérée comme suit :

$$\mathbf{ESIM} = \frac{\sum_{(x,y)} \mathbf{W}(x,y) \times \mathbf{S}(x,y)}{\sum_{(x,y)} \mathbf{W}(x,y)} \quad (1.10)$$

Où la moyenne pondérée est effectuée dans tous les emplacements de pixels  $(x, y)$ . [12]

➤ **GFM** (Gabor Feature-based Model)

À chaque emplacement de pixel  $(x, y)$ , la réponse de caractéristique Gabor de la SCI de référence (c'est-à-dire  $G_r(x, y)$ ) et de la SCI déformée (c'est-à-dire  $G_d(x, y)$ ) seront prises en compte, et la valeur la plus élevée de ces deux quantités sera exploitée comme facteur de pondération pour refléter le phénomène mentionné ci-dessus. Ainsi, une carte de poids  $\omega(x, y)$  peut être générée selon :

$$\omega(x, y) = \max\{|G_r(x, y)|, |G_d(x, y)|\} \quad (1.11)$$

Désigne la fonction de valeur absolue. Par conséquent, le score final d'évaluation de la qualité d'image peut être obtenu en effectuant la moyenne pondérée sur tous les emplacements de pixel  $(x, y)$  de la carte de qualité locale  $S_Q(x, y)$  comme suit : [13]

$$\mathbf{GFM} = \frac{\sum_{(x,y)} \omega(x,y) \times \mathbf{S}_Q(x,y)}{\sum_{(x,y)} \omega(x,y)} \quad (1.12)$$

$\omega(x, y)$  : Le poids map

$S_Q(x, y)$ : La qualité locale

➤ **SVQI** (Structural Variation based Quality Index)

Le nouvel indice de qualité appelé SVQI (Structural Variation based Quality Index) repose sur la variation structurelle. Pour tenir compte de la perception, ils ont subdivisé la structure en deux catégories : les structures globales pour la perception de base et les structures locales pour la perception détaillée des êtres humains. Ainsi, une combinaison systématique de mesure des variations des structures globales et locales est faite afin de prédire le score final de qualité de SCI.

## 1.5 Conclusion

Dans ce chapitre, nous avons abordé les concepts fondamentaux des images, ainsi que les définitions liées à la qualité des images de contenu d'écran. Nous avons également présenté les différentes méthodes d'évaluation de la qualité d'image contenu d'écran et nous avons présenté le principe de quelques métriques avec référence complète.

# **Méthodes des régressions**

## 2 Chapitre 02 : Méthodes des régressions

### 2.1 Introduction

L'apprentissage automatique consiste à montrer une grande quantité de données à une machine afin qu'elle puisse apprendre, prédire, trouver des modèles ou classer des données, plusieurs algorithmes d'apprentissage automatiques existent dans la littérature, d'où l'algorithme par régression.

Dans ce chapitre on a présenté la définition et le type de l'apprentissage automatique et quelque algorithme des régressions.

### 2.2 Apprentissage automatique

#### 2.2.1 Définition

L'apprentissage automatique est une approche d'analyse de données qui permet aux ordinateurs de découvrir des informations cachées sans être explicitement programmés pour les trouver. Grâce à des algorithmes d'apprentissage itératif, cette méthode automatise le développement de modèles analytiques. Elle permet ainsi aux ordinateurs d'apprendre à partir des données et de trouver des motifs, des relations ou des prédictions sans une programmation spécifique pour chaque cas.[32]

#### 2.2.2 Les types apprentissage automatique

##### ➤ Apprentissage supervisé

Dans l'apprentissage supervisé, les données d'apprentissage comprennent des étiquettes ou des solutions pour la variable à prédire. Le but est de définir une règle de prédiction qui mappe les variables observées vers la variable prédite. Cela se fait en optimisant les critères de qualité à l'aide d'un ensemble de règles possibles.

L'apprentissage supervisé est couramment utilisé dans les problèmes de classification et de régression : [32]

- **La classification**

visée à prédire une catégorie pour la variable de sortie, comme la détection de fraude par carte de crédit, la détection de spam dans les emails ou l'analyse du sentiment de texte. [32]

- **La régression**

visée à prédire une valeur réelle pour la variable de sortie, comme le prix de l'immobilier ou le cours de bourse.

Ces problèmes peuvent également inclure la prévision et la prédiction de séries temporelles, où l'on cherche à anticiper des valeurs futures en se basant sur des données passées. [32]

- **Apprentissage non supervisé**

Dans l'apprentissage non supervisé, les données d'apprentissage ne sont pas étiquetées, ce qui signifie qu'il n'y a pas de réponse prédéfinie à prédire. Le système tente d'apprendre sans avoir un enseignant pour le guider. Cela permet d'explorer des problèmes où nous avons peu ou pas d'idée de ce à quoi devraient ressembler les résultats.

L'apprentissage non supervisé comprend notamment :

- **Le regroupement ou clustering**

Il s'agit de diviser un ensemble de données en groupes de manière à ce que les données appartenant au même groupe se ressemblent davantage que celles des autres groupes. L'objectif est de découvrir des structures ou des similarités dans les données.

- **L'association**

Il s'agit de découvrir des relations intéressantes entre les variables dans de grandes bases de données. Cela permet de détecter des associations fréquentes ou des règles de corrélation entre les différents attributs des données

- **L'apprentissage semi-supervisé**

L'apprentissage semi-supervisé est une approche qui combine à la fois des données étiquetées et non-étiquetées pour l'entraînement d'un modèle. Généralement, seule une petite

quantité de données est étiquetée, tandis qu'une grande quantité de données reste non-étiquetée. Cela s'explique par le fait que l'obtention d'étiquettes pour les données peut être coûteuse ou difficile.[33]

L'apprentissage semi-supervisé peut être utilisé avec différentes méthodes d'apprentissage telles que la classification, la régression et la prédiction. Les données étiquetées aident à guider le modèle et à lui apprendre les relations entre les caractéristiques et les étiquettes correspondantes, tandis que les données non-étiquetées fournissent des informations supplémentaires pour améliorer la généralisation du modèle.[8]

### ➤ **L'apprentissage par renforcement**

L'apprentissage par renforcement est un type d'apprentissage qui se fait par interaction avec l'environnement, sans supervision. Le principe repose sur le concept d'essai et d'erreur, où le système apprend en prenant des actions et en observant les résultats obtenus. Chaque action est associée à une récompense qui représente la qualité de l'action.

L'objectif de l'apprentissage par renforcement est de déterminer la stratégie comportementale optimale qui maximise la récompense totale obtenue. Pour cela, le système reçoit un signal de renforcement, qui est un retour d'information sur la qualité de ses actions. Ce signal guide l'apprentissage et permet d'ajuster les actions pour atteindre de meilleurs résultats.

Il existe deux principaux types d'apprentissage par renforcement : l'apprentissage Monte Carlo et l'apprentissage par différence temporelle. Dans l'apprentissage Monte Carlo, les récompenses sont attribuées à la fin de chaque séquence d'actions, lorsqu'un état "terminal" est atteint. Dans l'apprentissage par différence temporelle, les récompenses sont évaluées et attribuées à chaque étape, ce qui permet un apprentissage plus rapide et adaptatif.

L'apprentissage par renforcement est particulièrement utile dans les domaines où l'environnement est dynamique et où des stratégies efficaces sont difficiles à trouver ou à automatiser manuellement, tels que la prévision financière à haute fréquence. Il offre la possibilité d'optimiser les actions en fonction des récompenses obtenues, permettant ainsi d'améliorer les performances dans des environnements complexes.[8]

## 2.3 Méthodes des régressions

### 2.3.1 Régression linéaire

#### 2.3.1.1 Historique et origine de la régression

Le concept de régression a été initialement introduit par Sir Francis Galton (1822-1911) dans le cadre d'une étude biologique sur l'hérédité. Son objectif était de démontrer l'existence d'une relation entre le diamètre des graines de pois de senteur et le diamètre moyen des graines de la descendance. Pour ce faire, il a tracé un graphique avec le diamètre des graines mères (X) en abscisse et le diamètre des graines issues de ces graines mères (Y) en ordonnée.

Galton a ainsi conclu qu'il existait effectivement une relation linéaire entre le diamètre des graines mères et celui de la descendance. De plus, il a observé que, en plus de cette relation linéaire, les graines de grand diamètre avaient tendance à produire des graines de plus petite taille, tandis que les graines de petit diamètre avaient tendance à produire des graines de plus grande taille. En d'autres termes, les graines présentaient une "régression" vers la moyenne.

C'est ainsi que le terme "régression" a été créé et utilisé pour ce type d'analyse [22]

#### 2.3.1.2 L'objectif de la régression linéaire

L'objectif est de modéliser la relation entre une variable dépendante Y et une ou plusieurs variables indépendantes  $X_1, \dots, X_p$ , en utilisant une fonction linéaire. On cherche à trouver les coefficients de régression qui minimisent l'erreur entre les valeurs prédites et les valeurs réelles de Y. Ainsi, l'objectif de la régression linéaire est de trouver une relation linéaire entre les variables explicatives et la variable à expliquer, afin de prédire ou expliquer au mieux les valeurs de Y en fonction des valeurs de  $X_1, \dots, X_p$ . [23]

#### 2.3.1.3 La régression linéaire simple

##### ✓ Modèle

Le modèle de régression linéaire simple est une variable endogène (dépendante) expliquée par une seule variable exogène (indépendante) mise sous la forme mathématique suivante : [24]

$$Y_t = B_0 + B_1 x_t + \varepsilon_t \quad \text{Pour } t=1, \dots, n \quad (2.1)$$

Avec :

$Y_t$ : La variable endogène (dépendante, à expliquer) à la date t.

$X_t$ : La variable exogène (indépendante, explicative) à la date t.

$B_0, B_1$ : Les paramètres inconnus du modèles.

$\varepsilon_t$ : L'erreur aléatoire du modèle.

n : nombre d'observations.

### ✓ Hypothèses du modèle

Le modèle repose sur les hypothèses suivantes :

1- $E(\varepsilon_t) = 0$  : l'erreur centrée.

2- $E(\varepsilon_t^2) = \sigma_\varepsilon^2$  : la variance de l'erreur est constante ( $V_t$ ).

3-  $E(\varepsilon_t, \varepsilon_{t'}) = 0$  si  $\varepsilon_t \neq \varepsilon_{t'}$ , les erreurs sont non corrélées (ou encore indépendantes).

4-  $Cov(x_t, \varepsilon_{t'}) = 0$ , l'erreur est indépendante des variables explicatives.

5- la variable exogène n'est pas aléatoire.

6- le modèle est linéaire en X par-rapport aux paramètres

### ✓ Estimation des paramètres

Soit le modèle suivant :

$$Y_t = B_0 + B_1 X_t + \varepsilon_t \quad (2,2)$$

L'estimation des paramètres  $B_0, B_1$  est obtenue en minimisant la somme des carrés des erreurs :

$$\text{Min} \sum_{i=1}^n \varepsilon_t^2 = \text{Min} \sum_{i=1}^n (Y_t - B_0 - B_1 X_t)^2 = \text{Min} S^2 \quad (2,3)$$

Pour que cette fonction ait un minimum, il faut que les dérivées par-rapport à  $B_0, B_1$  soient nuls.

$$\frac{\partial S}{\partial B_0} = 0 \Leftrightarrow 2 \sum_{t=1}^n (Y_t - B_0 - B_1 X_t)(-1) = 0 \Rightarrow \sum_{t=1}^n Y_t = nB_0 + B_1 \sum_{t=1}^n X_t \dots \dots (2, 4, 1)$$

$$\frac{\partial S}{\partial B_1} = 0 \Leftrightarrow 2 \sum_{t=1}^n (Y_t - B_0 - B_1 X_t)(-X_t) = 0 \Rightarrow \sum_{t=1}^n Y_t X_t = B_0 \sum_{t=1}^n X_t + B_1 \sum_{t=1}^n X_t^2 \dots (2, 5, 2)$$

En notant  $\hat{B}_0$  et  $\hat{B}_1$  les solutions des équations (1) et (2), on obtient d'après (1) :

$$\hat{B}_0 = \frac{\sum_{t=1}^n Y_t}{n} - \hat{B}_1 \frac{\sum_{t=1}^n X_t}{n} \quad (2, 6)$$

Ou bien

$$\hat{B}_0 = \bar{Y} - n\bar{X} \quad \text{Puisque} \quad \left( \frac{\sum_{t=1}^n Y_t}{n} \right) = \bar{Y} \text{ et } \left( \frac{\sum_{t=1}^n X_t}{n} \right) = \bar{X} \quad (2, 7)$$

En remplaçant la valeur de  $\hat{B}_0$  dans l'équation (2), on obtient :

$$\sum_{t=1}^n Y_t X_t - \bar{Y} \sum_{t=1}^n X_t = \hat{B}_1 (\sum_{t=1}^n X_t^2 - \bar{X} \sum_{t=1}^n X_t) \quad (2, 8)$$

D'où

$$\hat{B}_1 = \frac{\sum_{t=1}^n X_t Y_t - \bar{Y} \sum_{t=1}^n X_t}{\sum_{t=1}^n X_t^2 - \bar{X} \sum_{t=1}^n X_t} = \frac{\sum_{t=1}^n X_t Y_t - n\bar{X}\bar{Y}}{\sum_{t=1}^n X_t^2 - n\bar{X}^2} = \frac{\sum_{t=1}^n (Y_t - \bar{Y})(X_t - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (2, 9)$$

Enfin les estimateurs des MCO du modèle de régression linéaire simple

$Y_t = B_0 + B_1 X_t + \varepsilon_t$  Sont :

$$\hat{B}_0 = \bar{Y} - n\bar{X} \quad \text{et} \quad \hat{B}_1 = \frac{\sum_{t=1}^n X_t Y_t - n\bar{X}\bar{Y}}{\sum_{t=1}^n X_t^2 - n\bar{X}^2} = \frac{\sum_{t=1}^n (Y_t - \bar{Y})(X_t - \bar{X})}{\sum_{t=1}^n (X_t - \bar{X})^2} \quad (2, 10)$$

### 2.3.1.4 La Régression linéaire multiple

#### ✓ Méthodes

Il existe plusieurs méthodes pour la régression linéaire multiple. Elles sont utilisées pour déterminer les variables indépendantes les plus influentes et les introduire dans le modèle de régression. Parmi ces méthodes, nous pouvons citer les suivantes : [29]

- **Méthode d'inclusion de toutes les variables**

Dans cette méthode, toutes les variables indépendantes sont introduites et étudiées ensemble pour évaluer leur impact sur la variable dépendante sans éliminer aucune variable. [29]

- **Méthode d'ajout séquentiel de variables**

Dans cette méthode, nous commençons par calculer tous les coefficients de corrélation entre chaque variable indépendante et la variable dépendante. Ensuite, nous ajoutons la variable indépendante ayant le coefficient de corrélation le plus élevé avec la variable dépendante. Ensuite, à chaque étape, nous ajoutons une nouvelle variable indépendante au modèle qui entraîne une augmentation significative du coefficient de détermination, tout en tenant compte de la signification statistique du coefficient de détermination à chaque fois qu'une nouvelle variable indépendante est ajoutée (calculée à l'aide du test F). Cette étape est répétée jusqu'à l'ajout de la dernière variable indépendante qui a un effet sur la variable dépendante. [29]

- **Méthode de suppression séquentielle de variables**

Dans cette méthode, toutes les variables indépendantes sont incluses dans le modèle de régression, et le coefficient de détermination entre toutes ces variables indépendantes et la variable dépendante est calculé à chaque étape. La variable indépendante qui, une fois supprimée, entraîne une diminution de la valeur du coefficient de détermination est considérée comme n'ayant pas d'effet sur la variable dépendante. Il existe une autre méthode qui nous permet de déterminer si une variable indépendante a un impact significatif sur la variable dépendante ou non, en calculant le degré d'impact en suivant la relation de corrélation entre la variable indépendante et la variable dépendante. Si la relation de corrélation est faible et non statistiquement significative, la variable indépendante est supprimée. [29]

- **Méthode des étapes successives**

Cette méthode combine les méthodes d'ajout séquentiel et de suppression séquentielle. À chaque étape, une variable indépendante est choisie, en commençant par la variable la plus

importante et influente, jusqu'à atteindre la variable la moins importante et influente. Le test F est utilisé pour sélectionner la signification statistique des coefficients de régression linéaire multiple afin de déterminer la signification statistique et l'importance de chaque coefficient dans le modèle de régression. [29]

### ✓ **Modèle**

Le modèle linéaire général est une généralisation du modèle de régression simple dans lequel peut être calculée en utilisant la méthode des matrices ou la méthode des moindres carrés. Cependant, cette dernière est la méthode la plus simple et la plus couramment utilisée pour estimer l'équation de régression linéaire multiple. Voici la formule : [25]

$$y_t = a_0 + a_1x_{1t} + a_2x_{2t} + \dots + a_kx_{kt} + \varepsilon_t \quad \text{Pour } t=1, \dots, n \quad (2,11)$$

Avec :

$y_t$  : Variable à expliquer à la date t.

$x_{1t}$  : Variable à explicative 1 à la date t.

$x_{2t}$  : Variable à explicative 2 à la date t.

.....

$x_{kt}$  : Variable à explicative k à la date t.

$a_0, a_1, \dots, a_k$  : paramètres du modèle.

$\varepsilon_t$  : Erreur de spécification (différence entre le modèle vrai et le modèle spécifié), cette erreur est inconnue et restera inconnue,

n : nombre d'observations.

### ✓ **Forme matricielle**

En écrivant le modèle, observation par observation, nous obtenons :

$$y_1 = a_0 + a_1x_{11} + a_2x_{21} + \dots + a_kx_{k1} + \varepsilon_1 \quad (2,12)$$

$$y_2 = a_0 + a_1x_{12} + a_2x_{22} + \dots + a_kx_{k2} + \varepsilon_2 \quad (2,13)$$

.....

$$y_t = a_0 + a_1x_{1t} + a_2x_{2t} + \dots + a_kx_{kt} + \varepsilon_t \quad (2,14)$$

$$y_n = a_0 + a_1x_{1n} + a_2x_{2n} + \dots + a_kx_{kn} + \varepsilon_n \quad (2,15)$$

Soit, sous forme matricielle :

$$Y_{(n,1)} = X_{(n,k+1)}a_{(k+1,1)} + \varepsilon_{(n,1)} \quad (2,16)$$

Avec :

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_t \\ \vdots \\ y_n \end{pmatrix}; X = \begin{pmatrix} 1 & x_{11} & x_{21} & \dots & x_{k1} \\ 1 & x_{12} & x_{22} & \dots & x_{k2} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{1t} & x_{2t} & \dots & x_{kt} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{1n} & x_{2n} & \dots & x_{kn} \end{pmatrix}; a = \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ a_k \end{pmatrix}; \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_t \\ \vdots \\ \varepsilon_n \end{pmatrix} \quad (2,17)$$

L'écriture sous forme matricielle rend plus aisée la manipulation du modèle linéaire général, c'est pourquoi nous l'adoptons par la suite.

✓ **Estimation et propriétés des estimateurs**

▪ **Estimation des coefficients de régression**

Soit le modèle sous forme matricielle à k variables explicatives et n observations :

$$Y = Xa + \varepsilon \quad (2,18)$$

Afin d'estimer le vecteur a composé des coefficients  $a_0, a_1, \dots, a_k$ , nous appliquons la méthode des Moindres Carrés Ordinaires (MCO) qui consiste à minimiser la somme des carrés des erreurs, soit :

$$\text{Min} \sum_{i=1}^n \varepsilon_i^2 = \text{Min} \varepsilon' \varepsilon = \text{Min}(Y - Xa)' (Y - Xa) = \text{Min}S \quad (2,19)$$

$$\frac{\partial S}{\partial a} = -2X'X + 2X'X\hat{a} = 0 \quad (2,20)$$

$$\hat{a} = (X'X)^{-1}X'Y \quad (2,21)$$

**A) Forme matricielle**

$$(X'X)\hat{a} = X'Y \quad (2,22)$$

$$\begin{pmatrix} n & \sum x_{1t} & \sum x_{2t} & \dots & \sum x_{kt} \\ \sum x_{1t} & \sum x_{1t}^2 & \sum x_{1t}x_{2t} & \dots & \sum x_{1t}x_{kt} \\ \sum x_{2t} & \sum x_{2t}x_{1t} & \sum x_{2t}^2 & \dots & \sum x_{2t}x_{kt} \\ \vdots & \dots & \dots & \dots & \dots \\ \sum x_{kt} & \sum x_{kt}x_{1t} & \sum x_{kt}x_{2t} & \dots & \sum x_{kt}^2 \end{pmatrix} \begin{pmatrix} \hat{a}_0 \\ \hat{a}_1 \\ \hat{a}_2 \\ \dots \\ \hat{a}_k \end{pmatrix} = \begin{pmatrix} \sum y_t \\ \sum x_{1t}y_t \\ \sum x_{2t}y_t \\ \dots \\ \sum x_{kt}y_t \end{pmatrix} \quad (2,23)$$

Le modèle estimé s'écrit :

$$y_t = \hat{a}_0 + \hat{a}_1x_{1t} + \hat{a}_2x_{2t} + \dots + \hat{a}_kx_{kt} + e_t \quad (2,24)$$

Avec  $e_i = y_i - \hat{y}_i$  ou  $e_i$  est le résidu, c'est-à-dire l'écart entre la valeur observée de la variable à expliquer et sa valeur estimée (ajustée).

**B) Cas particulier** : cas des données centrées sur la moyenne

$$\begin{pmatrix} \hat{a}_0 \\ \hat{a}_1 \\ \hat{a}_2 \\ \dots \\ \hat{a}_k \end{pmatrix} = \begin{pmatrix} \text{Var}(x_1) & \text{Cov}(x_1, x_2) & \text{Cov}(x_1, x_3) & \dots & \text{Cov}(x_1, x_k) \\ \text{Cov}(x_2, x_1) & \text{Var}(x_2) & \text{Cov}(x_2, x_3) & \dots & \text{Cov}(x_2, x_k) \\ \text{Cov}(x_3, x_1) & \text{Cov}(x_3, x_2) & \text{Var}(x_3) & \dots & \text{Cov}(x_3, x_k) \\ \dots & \dots & \dots & \dots & \dots \\ \text{Cov}(x_k, x_1) & \text{Cov}(x_k, x_2) & \text{Cov}(x_k, x_3) & \dots & \text{Var}(x_k) \end{pmatrix}^{-1} \times \begin{pmatrix} \text{Cov}(x_1, y) \\ \text{Cov}(x_2, y) \\ \text{Cov}(x_3, y) \\ \dots \\ \text{Cov}(x_k, y) \end{pmatrix} \quad (2,25)$$

Avec :

$$\hat{a}_0 = \bar{y} - \hat{a}_1\bar{x}_1 - \hat{a}_2\bar{x}_2 - \dots - \hat{a}_k\bar{x}_k \quad (2,26)$$

**C) Hypothèses et propriétés des estimateurs**

➤ **Hypothèses Stochastiques**

**-H1** : les valeurs  $x_{i,t}$  sont observées sans erreur.

**-H2** :  $E(\varepsilon_t) = 0$  L'espérance mathématique de l'erreur est null.

**-H3** :  $E(\varepsilon_t^2) = \sigma_\varepsilon^2$  la variance de l'erreur est constante ( $\forall_t$ ) (homoscédasticité)

**-H4** :  $E(\varepsilon_t, \varepsilon_{t'}) = 0$  si  $t \neq t'$  les erreurs sont non corrélées (ou encore indépendantes).

**-H5** :  $Cov(x_{it}, \varepsilon_t) = 0$ , l'erreur est indépendante des variables explicatives.

### ➤ Hypothèses Structurelles

**-H6** : absence de colinéarité entre les variables explicatives. Cela implique que matrice  $(X'X)$  est régulière et que la matrice inverse  $(X'X)^{-1}$  existe.

**-H7** :  $(X'X)/n$  : tend vers une matrice finie non singulière.

**-H8** :  $n > k + 1$ , le nombre d'observations est supérieur au nombre des séries explicatives.

### ➤ Propriétés des estimateurs

#### Rappel

Estimateur sans biais :  $E(\hat{a}) = a$

Estimateur convergent :  $\lim_{T \rightarrow \infty} (\hat{a}) = 0$

Avec :  $\hat{a} = (X'X)^{-1} X'Y = (X'X)^{-1} X'(Xa + \varepsilon) = a + (X'X)^{-1} X'\varepsilon$  (2,26)

Et  $V(\hat{a}) = E(\hat{a} - E(\hat{a}))^2 = E[(\hat{a} - a)(\hat{a} - a)'] = \sigma_\varepsilon^2 (X'X)^{-1}$  (2,27)

$$V(\hat{a}) = \sigma_\varepsilon^2 \frac{1}{T} \left( \frac{1}{T} X'X \right)^{-1} \quad (2,28)$$

On calcule  $V(a) = \sigma_\varepsilon^2 (X'X)^{-1}$  à l'aide de l'estimateur de  $\sigma_\varepsilon^2$  qui s'écrit comme suit :

$$\hat{\sigma}_\varepsilon^2 = \frac{\sum_{t=1}^T e_t^2}{T-K-1} = \frac{SCR}{T-K-1} \quad (2,29)$$

$$V(\hat{a}) = \Omega_{\hat{a}} = \sigma_\varepsilon^2 (X'X)^{-1} \text{ et } \hat{\Omega}_{\hat{a}} = \hat{\sigma}_\varepsilon^2 (X'X)^{-1} \quad (2,30)$$

#### Théorème de Gauss-Markov

L'estimateur  $a = (X'X)^{-1}X'Y$  des moindres carrés est qualifié de BLUE (Best Linear Unbiased Estimator), car il s'agit du meilleur estimateur linéaire sans biais (au sens qu'il fournit les variances les plus faibles pour les estimateurs).

### ✓ Équation d'analyse de la variance et qualité d'un ajustement

Comme pour le modèle de régression simple, nous avons :

$$a) \sum_t y_t = \sum_t \hat{y}_t \rightarrow \bar{y}_t = \bar{\hat{y}}_t$$

$$b) \sum_t e_t = 0$$

De ces deux relations, nous en déduisons l'équation fondamentale d'analyse de la variance :

$$\sum_t (y_t - \bar{y}_t)^2 = \sum_t (y_t - \hat{y}_t)^2 + \sum_t e_t^2 \quad (2,31)$$

$$\text{SCT} = \text{SCE} + \text{SCR} \quad (2,32)$$

### ✓ Qualité d'un ajustement :

$$R^2 = \frac{\text{SCE}}{\text{SCT}} = \frac{\sum_t (\hat{y}_t - \bar{y}_t)^2}{\sum_t (y_t - \bar{y}_t)^2} = 1 - \frac{\text{SCR}}{\text{SCT}} \quad (2,33)$$

$R^2$  : coefficient de détermination

$R$  : coefficient de corrélation multiple

Dans le cas de données centrées (moyenne nulle) et seulement dans ce cas, le coefficient de détermination est égal à :

$$R^2 = \frac{\hat{Y}'\hat{Y}}{Y'Y} = 1 - \frac{e'e}{Y'Y} \quad (2,34)$$

Cette qualité de l'ajustement et l'appréciation que l'on a du  $R^2$  doivent être tempérées par le degré de liberté de l'estimation.

On calcule le  $R^2$  ajusté noté  $\bar{R}^2$  :

$$\bar{R}^2 = 1 - \frac{T-1}{T-k-1}(1 - R^2) \quad (2,35)$$

On  $\bar{R}^2 < R^2$  et si T est grand  $\bar{R}^2 \approx R^2$

### Remarque

- Le  $R^2$  ne permet de comparer que des modèles ayant le même nombre de variables explicatives, le même nombre d'observations et la même forme (on ne peut pas comparer un modèle simple avec un modèle en log).
- Lorsque l'on ajoute des variables explicatives supplémentaires dans un modèle, le  $R^2$  a tendance à augmenter sans qu'il y ait forcément amélioration du modèle. C'est pourquoi, lorsque l'on veut comparer des modèles qui n'ont pas le même nombre de variables explicatives, on utilise le  $\bar{R}^2$ .
- En général, lorsque les modèles n'ont pas le même nombre de variables explicatives, on utilise pour comparer les modèles le critère du :

$$S = \hat{\sigma}_\varepsilon = \sqrt{\frac{e'e}{T-k-1}} \quad (2,36)$$

Le meilleur modèle est celui qui a le S le plus petit.

### Exemple

Soit le modèle à trois variables explicatives :

$$y_t = a_0 + a_1x_{1t} + a_2x_{2t} + a_3x_{3t} + \varepsilon_t$$

Nous disposons des données du tableau 2.

1-Mettre le modèle sous forme matricielle en spécifiant bien les dimensions de chacune des matrices.

2-Estimer les paramètres du modèle.

3-Calculer l'estimation de la variance de l'erreur ainsi que les écarts types de chacun des coefficients.

4-Calculer le  $R^2$  et le  $\bar{R}^2$

t	y	$x_1$	$x_2$	$x_3$
1	12	2	45	121
2	14	1	43	132
3	10	3	43	154
4	16	6	47	145
5	14	7	42	129
6	19	8	41	156
7	21	8	32	132
8	19	5	33	147
9	21	5	41	128
10	16	8	38	163
11	19	4	32	161
12	21	9	31	172
13	25	12	35	174
14	21	7	29	180

Tableau 1 Les donnés

**Solution**

1-Forme matricielle :

Nous disposons de 14 observations et trois variables explicatives, le modèle peut donc s'écrire :

$$Y = Xa + \varepsilon \quad \text{Avec :}$$

$$Y = \begin{pmatrix} 12 \\ 14 \\ 10 \\ \vdots \\ 21 \end{pmatrix}; X = \begin{pmatrix} 1 & 2 & 45 & 121 \\ 1 & 1 & 43 & 132 \\ 1 & 3 & 43 & 154 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 7 & 29 & 180 \end{pmatrix}; a = \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ a_3 \end{pmatrix}; \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_t \\ \vdots \\ \varepsilon_{14} \end{pmatrix}$$

2- Estimation des paramètres :

$$\hat{a} = (X'X)^{-1} X'Y$$

Calcul de  $X'X$  et de  $(X'X)^{-1}$

$$\begin{aligned}
 X'X &= \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 2 & 1 & 3 & \dots & 7 \\ 45 & 43 & 43 & \dots & 29 \\ 121 & 132 & 154 & \dots & 180 \end{pmatrix} \begin{pmatrix} 1 & 2 & 45 & 121 \\ 1 & 1 & 43 & 132 \\ 1 & 3 & 43 & 154 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 7 & 29 & 180 \end{pmatrix} \\
 &= \begin{pmatrix} 14 & 85 & 532 & 2094 \\ 85 & 631 & 3126 & 13132 \\ 532 & 3126 & 20666 & 78683 \\ 2094 & 13132 & 78683 & 317950 \end{pmatrix} \\
 (X'X)^{-1} &= \begin{pmatrix} 20,1684 & 0,015065 & -0,23145 & -0,07617 \\ 0,015065 & 0,013204 & 0,001194 & -0,00094 \\ -0,23145 & 0,001194 & 0,003635 & 0,000575 \\ -0,07617 & -0,00094 & 0,000575 & 0,000401 \end{pmatrix}
 \end{aligned}$$

Calcul de  $X'Y$

$$X'Y = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 2 & 1 & 3 & \dots & 7 \\ 45 & 43 & 43 & \dots & 29 \\ 121 & 132 & 154 & \dots & 180 \end{pmatrix} \begin{pmatrix} 12 \\ 14 \\ 10 \\ \vdots \\ 21 \end{pmatrix} = \begin{pmatrix} 248 \\ 1622 \\ 9202 \\ 37592 \end{pmatrix}$$

Calcul de  $\hat{a}$  :

$$\begin{aligned}
 \hat{a} &= (X'X)^{-1}X'Y = \begin{pmatrix} 20,1684 & 0,015065 & -0,23145 & -0,07617 \\ 0,015065 & 0,013204 & 0,001194 & -0,00094 \\ -0,23145 & 0,001194 & 0,003635 & 0,000575 \\ -0,07617 & -0,00094 & 0,000575 & 0,000401 \end{pmatrix} \begin{pmatrix} 248 \\ 1622 \\ 9202 \\ 37592 \end{pmatrix} \\
 &= \begin{pmatrix} 32,89132 \\ 0,081900 \\ -0,38136 \\ -0,03713 \end{pmatrix}
 \end{aligned}$$

$$\hat{a}_0 = 32,89132, \hat{a}_1 = 0,081900, \hat{a}_2 = -0,38136, \hat{a}_3 = 0,03713,$$

3-Calcul de  $\hat{\sigma}_\varepsilon^2$  et de  $\hat{\sigma}_{\hat{a}}^2$

$$\hat{\sigma}_\varepsilon^2 = \frac{e'e}{n-K-1} \text{ Nous devons donc calculer le résidu } e.$$

$$e = Y - \hat{Y} = Y - X\hat{a}$$

$$\text{Soit } e_t = y_t - (\hat{a}_0 + \hat{a}_1x_{1t} + \hat{a}_2x_{2t} + \hat{a}_3x_{3t})$$

$$e_t = y_t - (32,89 + 0,08x_{1t} - 0,38x_{2t} + 0,03x_{3t})$$

Par exemple pour  $e_1$  :

$$e_1 = y_1 - 32,89 - 0,80x_{11} + 0,38x_{21} + 0,03x_{31}$$

$$e_1 = 12 - 32,89 - 0,80 \times 2 + 0,38 \times 45 + 0,03 \times 121 = -0,84$$

Le tableau 2 présente l'ensemble des résultats.

Par construction, la somme des résidus est bien nulle.

$$\hat{\sigma}_\varepsilon^2 = \frac{e'e}{n - k - 1} = \frac{\sum_{t=1}^{t=14} e_t^2}{14 - 3 - 1} = \frac{67,45}{10} = 6,745$$

t	$y_t$	$\hat{y}_t$	$e_t$	$e_t^2$
1	12	12.84	-0.84	0,71
2	14	12.39	1.61	2.58
3	10	13.18	-3.18	10.11
4	16	13.39	1.61	2.58
5	14	17.70	-3.70	13.67
6	19	17.88	1.12	1.26
7	21	22.20	-1.20	1.44
8	19	18.86	0.14	0.02
9	21	16.51	4.49	20.14
10	16	18.76	-2.76	7.63
11	19	17.92	1.08	1.17
12	21	21.90	-0.90	0.81
13	25	22.71	2.29	5.27
14	21	20.76	0.24	0.06
Somme			0	67,45

Tableau 2.2 le résultat de solution

La matrice des variances et covariances estimées des coefficients nous est donnée par :

$$\hat{\Omega}_{\hat{a}} = \hat{\sigma}_\varepsilon^2 (X'X)^{-1}$$

$$\hat{\Omega}_{\hat{a}} = 6.745 \times \begin{pmatrix} 20.16864 & 0.015065 & -0.23145 & -0.07617 \\ 0.015065 & 0.013204 & 0.001194 & -0,00094 \\ -0.23145 & 0.001194 & 0.003635 & 0.000575 \\ -0.07617 & -0.00094 & -0.000575 & 0.000401 \end{pmatrix}$$

Les variances des coefficients de régression se trouvent la première diagonale :

$$\hat{\sigma}_{\hat{a}_0}^2 = 6.745 \times 20.17 = 136.04 \rightarrow \hat{\sigma}_{\hat{a}_0}^2 = 11.66$$

$$\hat{\sigma}_{\hat{a}_1}^2 = 6.745 \times 0.013 = 0.087 \rightarrow \hat{\sigma}_{\hat{a}_1}^2 = 0.29$$

$$\hat{\sigma}_{\hat{a}_2}^2 = 6.745 \times 0.0036 = 0.024 \rightarrow \hat{\sigma}_{\hat{a}_2}^2 = 0.15$$

$$\hat{\sigma}_{\hat{a}_3}^2 = 6.745 \times 0.0004 = 0.0026 \rightarrow \hat{\sigma}_{\hat{a}_3}^2 = 0.05$$

4-le calcul du  $R^2$  est effectué à partir de formule :

Nous connaissons  $e' e = 67,45$  il convient de calculer  $\sum_t (y_t - \bar{y})^2 = 226.86$ .

$$R^2 = 1 - \frac{\sum_t e_t^2}{\sum_t (y_t - \bar{y})^2} = 1 - \frac{67.45}{226.86} = 0.702$$

Le  $\bar{R}^2$  corrigé est donné par :

$$\bar{R}^2 = 1 - \frac{n-1}{n-k-1} (1 - R^2) = 1 - \frac{14-1}{14-4} (1 - 0.702) = 0.613$$

### 2.3.1.5 Régression Ridge

La régression Ridge est une méthode utilisée pour ajuster les modèles et analyser des données présentant une multicollinéarité. Elle implémente une régularisation L2. Lorsque la multicollinéarité est présente et que les moindres carrés ne sont pas biaisés, les prédictions peuvent s'éloigner des valeurs réelles en raison de l'importance des variances.

La fonction de coût de la régression Ridge est définie comme suit :

$$\text{Min}(\|\mathbf{y} - \mathbf{x}(\boldsymbol{\theta})\|^2 + \lambda \|\boldsymbol{\theta}\|^2) \quad (2.37)$$

Ici, lambda ( $\lambda$ ) est le terme de pénalité. Dans la fonction Ridge, il est généralement noté en tant que paramètre alpha. En ajustant les valeurs d'alpha, nous contrôlons le niveau de pénalité. Plus les valeurs d'alpha sont élevées, plus la pénalité est importante, ce qui entraîne une réduction de l'amplitude des coefficients.

Dans tous les modèles de régression en apprentissage automatique, l'équation de régression classique est utilisée comme base, et elle peut être exprimée comme suit :

$$Y = XB + e \quad (2,38)$$

Y : représente la variable dépendante,

X : représente les variables indépendantes,

B : est le vecteur des coefficients de régression à estimer,

e : représente les erreurs ou résidus.

L'ajout de la fonction lambda à cette équation permet de prendre en compte la variance qui n'est pas évaluée par le modèle classique [36]

### 2.3.1.6 Régression lasso

L'algorithme Lasso (Least Absolute Shrinkage and Selection Operator) introduit un terme de pénalisation dans la fonction objectif pour favoriser la parcimonie du modèle final, contrairement aux méthodes de régression classiques. L'objectif principal de cette méthode est d'améliorer la robustesse du modèle sur un échantillon indépendant de la base d'apprentissage. Cette amélioration se traduit par une réduction de la variance du modèle, même si cela entraîne intentionnellement un biais du modèle par le terme de pénalité.

L'équation de prédiction dans la régression Lasso est formulée comme suit :

$$E[Y/X] = g^{-1} = (B_0 + B_1 * X_1 + \dots + B_p * X_p) \quad (2, 39)$$

Y : représente la variable cible,

$X = (X_1, \dots, X_p)$  : est la matrice de conception contenant les variables explicatives,

$B = (B_0, \dots, B_p)$  : est le vecteur des p+1 coefficients à estimer.

Que ce soit pour minimiser l'erreur quadratique dans le cadre d'une régression linéaire ou pour maximiser la vraisemblance, la régression Lasso ajoute un terme de pénalité correspondant à la norme L1 du vecteur  $\beta$ . [37]

### 2.3.1.7 Machine à vecteurs de support

Le Support Vector Machine (SVM), ou machine à vecteurs de support, est une technique de machine learning largement utilisée pour la classification et la régression en raison de sa grande précision.

Les SVM sont utilisés lorsque les données ont exactement deux classes. L'algorithme SVM classe les données en trouvant le meilleur hyperplan qui sépare les points de données des différentes classes avec la plus grande marge possible (voir figure 2.1). Les SVM peuvent également être utilisés avec plus de deux classes, où le modèle créera un ensemble de sous-ensembles de classification binaire. Dans le cas où la frontière entre les classes n'est pas linéaire dans l'espace vectoriel d'entrée, un hyperplan multidimensionnel non linéaire est utilisé. Pour cela, une fonction noyau est utilisée pour mapper le vecteur d'entrée vers un espace de dimension supérieure, où un hyperplan linéaire peut séparer les différentes classes avec une marge maximale pour réduire les erreurs de classification. L'emplacement de la frontière est déterminé par un sous-ensemble de points de données historiques appelés vecteurs de support. La même motivation s'applique à la recherche et à l'optimisation des frontières dans l'espace dimensionnel supérieur pour la régression. [26]

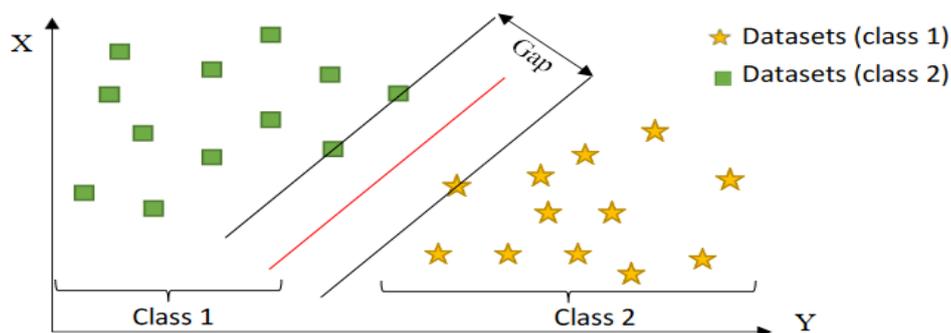


Figure 2.1 Machines à vecteurs de support

### 2.3.1.8 Les avantages et les limites de régression linéaire

#### ✓ Les avantages :

La régression linéaire offre une mise en œuvre simple et facilite l'interprétation des coefficients obtenus.

Lorsque la relation entre la variable indépendante et la variable dépendante est linéaire, la régression linéaire est souvent privilégiée car elle présente une complexité moindre par rapport à d'autres algorithmes.

La régression linéaire est susceptible de sur-ajustement, mais elle peut être évitée en utilisant certaines techniques de réduction de la dimensionnalité, des techniques de régularisation (L1 et L2) et la validation croisée. [27]

✓ **Les limites :**

Les prérequis stricts en termes de distribution des données, le problème de la multicolinéarité, la sensibilité aux données aberrantes, la limitation de la modélisation de la complexité, ainsi que les problèmes de sur ajustement et de sous-ajustement. Ces limitations doivent être prises en compte lors de l'utilisation de la régression linéaire et il peut être nécessaire de recourir à des méthodes plus avancées lorsque les conditions de la régression linéaire ne sont pas remplies ou que la complexité de la relation entre les variables nécessite une approche plus sophistiquée. [28]

## **2.4 Conclusion**

Dans ce chapitre, nous avons abordé la définition et les types d'apprentissage automatique, ainsi que quelques algorithmes de régression. Les algorithmes présentent des différences entre eux, c'est pourquoi nous avons décidé d'expliquer en détail l'algorithme linéaire choisi.

# **Résultats Expérimentaux**

## 3 Chapitre 03 : Résultats Expérimentaux

### 3.1 Introduction

Notre objectif est de proposer une nouvelle méthode pour l'évaluation de la qualité des images de contenu d'écran basée sur la méthode de régression linéaire ; nommée SCIQA-RL (Screen Content Image Quality Assessment based Regression Linear). Cette méthode est le résultat de la combinaison de quelques méthodes de base les plus populaires afin d'exploiter les avantages de certaines métriques et de réduire l'influence de leurs limites.

Dans ce chapitre, nous présenterons en détails notre application tout en commençant par les outils utilisés et base d'image utilisé et approche proposé et nous expliquerons les résultats obtenus.

### 3.2 Les outils utilisés

Dans ce qui suit nous avons présenté les outils utilisés dans notre travail :

#### 3.2.1 Le matériel

Nous avons utilisé un laptop de marque DELL avec les capacités suivantes :

- Intel® Core™ i5-3340M CPU @ 2,70 GHz
- Disque dur 500 GO
- RAM 4GO
- Windows 10 Professionnel

#### 3.2.2 Les logiciels

##### ✓ Anaconda

Anaconda est une distribution open source et gratuite des langages de programmation Python e, conçue spécialement pour le développement d'applications dans le domaine de la science des données et de l'apprentissage automatique. Cette distribution facilite la gestion et le déploiement des packages, notamment pour le traitement de données à grande échelle, l'analyse prédictive et l'informatique scientifique.

Elle repose sur le système de gestion de packages conda, qui permet de gérer les versions des packages de manière efficace. La distribution Anaconda est largement utilisée par plus de

6 millions d'utilisateurs à travers le monde. Elle propose une vaste sélection de plus de 250 packages populaires dédiés aux données scientifiques, et elle est compatible avec les systèmes d'exploitation Windows, Linux et MacOS.

### ✓ Python

Python est le langage de programmation open source le plus largement utilisé par les professionnels de l'informatique. Il est particulièrement prisé dans des domaines tels que la gestion de l'infrastructure, l'analyse de données et le développement de logiciels. Python se distingue par sa simplicité et sa facilité d'apprentissage, ce qui en fait un choix populaire parmi les développeurs.

Python offre une vaste bibliothèque de modules et de packages, disponibles sur la plupart des plateformes, ce qui permet aux utilisateurs de les redistribuer gratuitement.

### 3.2.3 Bibliothèque

Nous mentionnerons ci-dessous quelques autres cadres et bibliothèques que nous avons utilisés, comme :

- Pandas.
- Numpy.
- PyQt5
- Matplotlib.
- pickle
- Scikit-learn

### ✓ Pandas

Est largement utilisée pour la manipulation et l'analyse de données tabulaires. Elle permet de lire, écrire, explorer et préparer les données. Pandas offre des outils pour filtrer, trier, agréger et nettoyer les données, ainsi que pour effectuer des calculs statistiques et des analyses avancées. Elle facilite également la visualisation des données. En résumé, Pandas est une bibliothèque essentielle pour travailler efficacement avec des données tabulaires en Python. [3]

### ✓ Pickle

Est utilisée pour la sérialisation et la désérialisation d'objets Python. Elle permet de convertir des objets en une représentation binaire pour les stocker, les transmettre ou les utiliser ultérieurement. Pickle est utile pour la sauvegarde d'objets, la communication entre processus et le stockage de données dans des bases de données. Il est important d'utiliser pickle avec prudence lors de la désérialisation d'objets provenant de sources non fiables pour éviter les risques de sécurité.

#### ✓ **Numpy**

Est une bibliothèque fondamentale en Python pour les calculs numériques et la manipulation de tableaux multidimensionnels. Elle offre des fonctionnalités avancées et des performances optimisées, ce qui en fait un outil essentiel pour les tâches liées aux données numériques et scientifiques.

#### ✓ **Matplotlib**

Est une bibliothèque essentielle en Python pour la création de graphiques et de visualisations de données. Elle offre une grande flexibilité et des fonctionnalités puissantes pour représenter les données de manière claire et informative.

#### ✓ **Scikit-learn**

Est un outil essentiel en Python pour effectuer des tâches d'apprentissage automatique. Elle offre une large gamme d'algorithmes, de fonctions et d'outils pour préparer les données, construire des modèles, évaluer leur performance et effectuer des prédictions.

### **3.3 Bases d'image utilisée**

Nous avons utilisé la base SCID (la description est dans le chapitre 1). Le choix de cette base revient qu'elle est la plus utilisée par les autres méthodes et pour permettre une comparaison des performances de notre méthode avec les autres.

### **3.4 Approche Proposée**

Nous avons proposé une nouvelle méthode d'évaluation de qualité d'image de contenu d'écran par la combinaison de 7 métriques avec référence complètes à savoir : GFM, GSS, SCDM, SCQI, SQMS, SVQI, ESIM (présenté dans le chapitre 1) ; pour ce fait nous avons utilisé la méthode de régression linéaire.

Tout d'abord, nous allons diviser les données en 2 parties (80 % pour les données d'entraînement, 20 % pour les données de test) et cela en utilisant la fonction proposée par Scikit-Learn comme `sklearn.model_selection.train_test_split` qui nous donne :

- `X_train` : paramètres des propriétés des images d'entraînement.
- `X_test` : paramètres des propriétés des images de test.
- `Y_train` : valeurs des propriétés des images d'entraînement.
- `Y_test` : valeurs des propriétés des images de test.

Les `X` présentent les valeurs des métriques utilisées sur les images de la base SCID, et les `Y` sont leurs valeurs subjectives correspond.

Les différents paramètres et valeurs utilisées dans Régression linéaire sont :

```
reg = LinearRegression( fit_intercept=True,
                        copy_X=True,
                        n_jobs=None,
                        positive=False)
```

### 3.5 Evaluation des résultats

Pour évaluer notre méthode, nous avons utilisé des paramètres de corrélation à savoir :

#### ✓ Corrélation Pearson (PRCC)

La corrélation de Pearson est la statistique de corrélation la plus utilisée pour mesurer le degré de la relation entre les variables linéairement liées. Par exemple, sur le marché boursier, si nous voulons mesurer la relation entre deux actions, la corrélation de Pearson est utilisée pour mesurer le degré de relation entre les deux. La corrélation point-bisériale est réalisée avec la formule de corrélation de Pearson sauf que l'une des variables est dichotomique.

Plus la valeur est grande plus le résultat soit bonne.

La formule suivante est utilisée pour calculer la corrélation de Pearson :

$$\text{PRCC} = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad (3,1)$$

$n$  nombre d'observations.

$\Sigma xy$  Somme des produits des partitions appariées.

$\Sigma x$  Somme des scores x.

$\Sigma y$  Somme des scores y.

$\Sigma x^2$  Somme des scores x au carré.

$\Sigma y^2$  Somme des scores y carré.

#### ✓ **Corrélation Spearman (SRCC)**

La corrélation de rang de Spearman est un test non paramétrique utilisé pour mesurer le degré d'association entre deux variables. Il a été développé par Spearman, donc est appelé la corrélation de rang de Spearman. Le test de corrélation de rang de Spearman ne suppose aucune hypothèse sur la distribution des données et constitue l'analyse de corrélation appropriée lorsque les variables sont mesurées sur une échelle au moins ordinale. Plus la valeur est grande plus le résultat soit bonne.

La formule suivante est utilisée pour calculer la corrélation de rang de Spearman :

$$SRCC = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2-1)} \quad (3,2)$$

$d_i$ : La différence entre les rangs des valeurs correspondant est  $X_i$  et  $y_i$ .

N : nombre de valeur dans chaque ensemble de données.

#### ✓ **Corrélation Kendall (KRCC)**

La corrélation de rang de Kendall est un test non-paramétrique qui mesure la force de la dépendance entre deux variables. Si nous considérons deux échantillons,  $N_c$  et  $N_d$ , où chaque taille d'échantillon est n, nous savons que le nombre total d'appariements avec a est  $N(N-1)/2$ . Plus la valeur est grande plus le résultat soit bonne.

La formule suivante est utilisée pour calculer la valeur de la corrélation de rang de Kendall:

$$KRCC = \frac{2(N_c - N_d)}{N(N-1)} \quad (3,3)$$

#### ✓ **Erreur quadratique moyenne (RMSE)**

L'erreur quadratique moyenne (RMSE, pour Root Mean Square Error) est une mesure de l'écart entre les valeurs prédites par un modèle et les valeurs réelles observées dans un ensemble de données. C'est une métrique couramment utilisée pour évaluer la performance d'un modèle de régression.

L'erreur quadratique moyenne est calculée en prenant la racine carrée de la moyenne des carrés des différences entre les valeurs prédites et les valeurs réelles. Mathématiquement, le calcul du RMSE pour un ensemble de données de taille  $n$  se fait selon la formule suivante :

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (3,4)$$

$\bar{y}$  Exprime les valeurs moyennes de  $y_i$

Plus la valeur est petite plus le résultat soit bonne.

Les fonctions qui affichent les résultats :

```
def spcc(x,Y):
    a , _ =pearsonr(np.squeeze(np.asarray(x)), np.squeeze(np.asarray(Y)))
    return str(a)
def srcc(x,Y):
    a , _ =spearmanr(np.array(x), np.array(Y))
    return str(a)
def krcc(x,Y):
    a , _ =kendalltau(np.array(x), np.array(Y))
    return str(a)
def rmse(x,Y):
    return str(np.sqrt(mean_squared_error(np.array(x), np.array(Y))))

y_pred = reg.predict(poly_features)

print('Y predict :')
print(y_pred)
```

Le tableau suivant présente les résultats obtenus par notre modèle et les autres méthodes de base utilisées dans la régression :

	<b>GFM</b>	GSS	SCDM	SCQI	SQMS	SVQI	ESIM
SPCC	<b>0,8760</b>	0,7609	0,7781	0,7854	0,8563	0,8610	0,8625
KRCC	<b>0,6843</b>	0,5422	0,5737	0,5826	0,6429	0,6501	0,6516
SRCC	<b>0,8758</b>	0,7490	0,7715	0,7814	0,8320	0,8385	0,8485
RMSE	<b>6,8296</b>	9,1890	8,8956	8,7646	7,3134	7,2026	7,1665

Tableau 3.1 évaluation par les coefficients de corrélation

Les résultats montrent que notre méthode **GFM** est la meilleure par ce que son **RMSE** est le plus petit et son **Spearman** est le plus grand (même pour Kendal et Pearson sont les plus grand)

### 3.6 L'interface et son contenu

Notre interface sous le nom « Evaluation de la qualité d'image contenu d'écran avec les algorithmes Régression Linéaire » (SCIQA-LR : Screen Content Image Quality Assessment based Linear Regression) contient 3 parties ; La figure 3.3 présente l'interface de notre application.

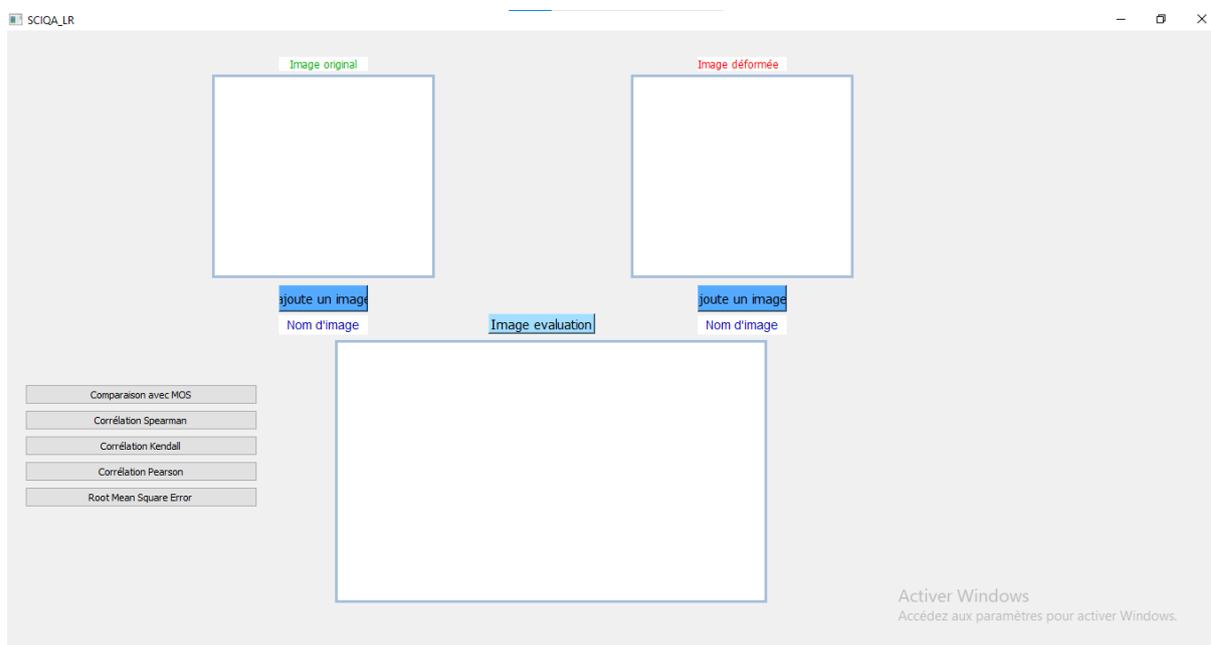


Figure 3.1 Interface d'évaluation de qualité d'image contenue d'écran

La **1ère partie** contient deux zones : une pour sélectionner et affiché l'image original et l'autre pour ajouter l'image déformée. la figure 3.4 présente un exemple de la partie d'image



Figure 3.2 Image originale et image déformée

La **2ème partie** Le bouton Image évaluation permet de sélectionner les métriques existant à appliquer pour évaluer la qualité d'image déformée. Le résultat est affiché juste au-dessous du nom de la métrique :

Metric	DistortedSCIs	GFM	GSS	SCDM	SCQI	SQMS	SVQI	ESIM	SCIQ_LR	MOS
Value	SCI07_6_5	38.338022270...	39.858561666...	39.576425689...	39.569634939...	38.508457567...	38.160514121...	34.546479697...	36.19971337	34.963
Niveau de distorsion		mauvaise	mauvaise	mauvaise						

Figure 3.3 Evaluation d'image par les différentes méthodes

La **3ème partie** nous permet l'évaluation des résultats où :

Le bouton **Comparaison avec MOS** permet de permettre d'afficher un nuage de points entre la métrique choisie et les valeurs subjective sur la base SCID.

Le bouton **Corrélation Spearman** permet d'afficher la valeur du paramètre SPCC des méthodes.

Le bouton **Corrélation Kendall** offre la possibilité de visualiser une comparaison entre les résultats obtenus par notre méthode.

Le Bouton **Corrélation Pearson** offre la possibilité de visualiser une comparaison entre les méthodes en fonction de la corrélation de Pearson.

Le Bouton **Erreur quadratique moyenne**, même chose que précédemment sauf que pour ce coefficient (comme indiquer au paravent : que plus la valeur de l'erreur quadratique moyenne est faible, plus le modèle est précis).

### 3.7 Conclusion

Dans ce chapitre, nous avons expliqué le concept fondamental de notre nouvelle approche pour évaluer la qualité des images de contenu d'écran, en se basant sur la régression, en particulier la méthode SCIQA-LR.

De plus nous avons introduire une application qui offre aux utilisateurs la possibilité d'évaluer la qualité des images de contenu d'écran à l'aide des métriques de référence les plus populaires et avec notre nouvelle méthode. Notre application permet aussi d'afficher les différents résultats de comparaisons.

## Conclusion générale

En conclusion, ce projet a abordé en détail l'utilisation de l'algorithme de régression linéaire multiple pour évaluer la qualité des images de contenu d'écran. Les images de contenu d'écran occupent une place de plus en plus importante dans notre vie quotidienne et sont susceptibles de divers types de distorsions, il est donc important d'évaluer leur qualité.

La première partie de ce mémoire a examiné en profondeur le problème de l'évaluation de la qualité des images de contenu d'écran, passé en revue diverses techniques existantes et présenté quelques méthodes objectives avec référence complète.

La deuxième partie a présenté quelques algorithmes de régression, en mettant particulièrement l'accent sur l'algorithme de régression linéaire multiple.

Dans la troisième partie, nous avons décrit en détail notre application spécifique et les résultats obtenus. L'évaluation de l'approche proposée, basée sur la base de données d'images de contenu d'écran SCID, a montré sa supériorité par rapport aux autres méthodes objectives avec référence complète, comme en témoignent les coefficients de Spearman, Kendall et Pearson.

En résumé, ce projet a confirmé l'efficacité de l'algorithme de régression linéaire multiple pour évaluer la qualité des images de contenu d'écran. Les résultats obtenus montrent que cette approche permet d'obtenir des estimations précises de la qualité des images, ce qui revêt une grande importance dans de nombreux domaines et ouvrent la voie à de futures recherches et applications potentielles dans divers domaines où une évaluation précise de la qualité des images est requise.

Cependant, il est important de reconnaître les limites de ce travail. Des améliorations futures pourraient inclure l'exploration d'autres algorithmes de régression et l'intégration de métriques supplémentaires pour une évaluation plus complète de la qualité des images de contenu d'écran.

---

## Références bibliographique

- [1] Merzougui, N. (2022). *Métaheuristiques pour l'évaluation objective de la qualité d'images et de vidéos* (Doctoral dissertation, Université de mohamed kheider biskra).
- [2] Sandeli, M. (2014). *Traitement d'images par des approches bio-inspirées Application à la segmentation d'images*. Université Constantine, 2.
- [3] <https://www.mygreatlearning.com/blog/what-is-ridge-regression/>, 25/05/23.
- [4] BOUCETTA, A. (2010), Etude de l'effet des Transformées de Décorrélation en Compression des Image Couleurs RG , (Mémoire Magistir UNIVERSITE DE BATNA).
- [5] M. Darpy Denis, Mme Le Nagard, E. (2018), Comment la qualité technique de l'image médiatisée par un écran ultra haute définition modifie-t-elle le traitement cognitif de l'information, la qualité d'expérience, et le rapport à la réalité, (Thèse doctorat l'Université Paris-Dauphine).
- [6] Aladine, C. (2010), Vers un système d'évaluation de la qualité d'image multi-critères. *Traitement du signal et de l'image* , (Thèse doctorat Université Paris-13)
- [7] Ni, Z., Ma, L., Zeng, H., Fu, Y., Xing, L., & Ma, K. K. (2017, November). SCID: A database for screen content images quality assessment. In *2017 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)* (pp. 774-779). IEEE.
- [8] Yang, H., Fang, Y., Lin, W., & Wang, Z. (2014, September). Subjective quality assessment of screen content images. In *2014 Sixth International Workshop on Quality of Multimedia Experience (QoMEX)* (pp. 257-262). IEEE.
- [9] Gu, K., Wang, S., Yang, H., Lin, W., Zhai, G., Yang, X., & Zhang, W. (2016). Saliency-guided quality assessment of screen content images. *IEEE Transactions on Multimedia*, 18(6), 1098-1110.

- [10] Layek, M. A., Mahmud, M. Z., Islam, M. R., Monira, M. S., Uddin, A. S., & Afroz, S. (2021) Center Emphasized Structural Contrast and a Saliency-induced Image Quality Index.
- [11] Ni, Z., Ma, L., Zeng, H., Cai, C., & Ma, K. K. (2016). Gradient direction for screen content image quality assessment. *IEEE Signal Processing Letters*, 23(10), 1394-1398
- [12] Ni, Z., Ma, L., Zeng, H., Chen, J., Cai, C., & Ma, K. K. (2017). ESIM: Edge similarity for screen content image quality assessment. *IEEE Transactions on Image Processing*, 26(10), 4818-4831.
- [13] Ni, Z., Zeng, H., Ma, L., Hou, J., Chen, J., & Ma, K. K. (2018). A Gabor feature-based quality assessment model for the screen content images. *IEEE Transactions on Image Processing*, 27(9), 4516-4528.
- [14] Tian, S., Zhang, L., Zou, W., Li, X., Su, T., Morin, L., & Deforges, O. (2021). Quality assessment of DIBR-synthesized views: An overview. *Neurocomputing*, 423, 158-178
- [15] Flusser, J., Farokhi, S., Höschl, C., Suk, T., Zitova, B., & Pedone, M. (2015). Recognition of images degraded by Gaussian blur. *IEEE transactions on Image Processing*, 25(2), 790-806.
- [16] Schmid, C., Soatto, S., & Tomasi, C. (2005). *Conference on Computer Vision and Pattern Recognition* (p. 1211p). IEEE Computer Society.
- [17] Gu, K., Zhai, G., Yang, X., Zhang, W., & Liu, M. (2013, September). Subjective and objective quality assessment for images with contrast change. In *2013 IEEE International Conference on Image Processing* (pp. 383-387). IEEE.
- [18] Raid, A. M., Khedr, W. M., El-Dosuky, M. A., & Ahmed, W. (2014). Jpeg image compression using discrete cosine transform-A survey. *arXiv preprint arXiv:1405.6147*.
- [19] HEMDANI.N.(2011),L'apport des bandelettes par rapport aux ondelettes dans les applications de traitement d'image, .

[20] Hao-Zhi Huang, Kun Xu, Ralph R Martin, Fei-Yue Huang, and Shi-Min Hu. «Efficient, edge-aware, combined color quantization and dithering». IEEE Transactions on Image Processing, 25(3) :1152–1162, 2015.

[21] Wang, Z., Bovik, A., Sheikh, H., and Simoncelli, E. (2004). «Image quality assessment : From error visibility to structural similarity». 13 :600–12.

[22] Francis Galton, Regression towards mediocrity in hereditary stature, Journal of the Anthropological Institute 15 : 246-63 ,1886.

[23]Christophe.C. ( 2017) cours Modèles de régression». (Université. France..)

[24]Dr BOUKRIF.N ( 2016), Cours Régression Linéaire simple et multiple,(Université Abderrahmane MIRA-Bejaia).

[25]Pr. Moad El kharrim , Cours Modèle de régression linéaire multiple

[26]Fatoumata.Y, Amor.A,( 2021) Machine learning pour la maintenance prédictive, (Mémoire MasterUniversité Larbi Ben Mhidi d'Oum El-Bouaghi).

[27]<https://stacklima.com/ml-avantages-et-inconvenients-de-la-regression-lineaire>  
24/5/2023

[28]<https://makeitup.fr/quels-sont-les-inconvenients-de-la-regression-lineaire/uncategorized/> 24/5/2023

[29]Abbane.A.( 2020) Cours de regression linéaire multiple,( Univercité kasdi Merbah Ouargla).

[30] J. Fruitet, "Outils et méthodes pour le traitement des images par ordinateur", Cours Université de Marne-la-vallée, France 2000.

- [31] A. Manzanera, " Les images numériques", cours traitement et reconnaissance d'image, Master IAD, Ecole Nationale Supérieure de Techniques Avancées/Unité d'Électronique et d'Informatique, Université Pierre et Marie CURIE, Paris 2005.
- [32] Géron, A. (2019). Machine Learning avec Scikit-Learn: Mise en oeuvre et cas concrets. Dunod.
- [33] [http://abdelhamid-djeffal.net/index.php?p=1\\_18\\_Cours](http://abdelhamid-djeffal.net/index.php?p=1_18_Cours), consulté le 10/05/2023
- [34] A. Abdelaziz, "Compression d'images par fractale", Thèse de magister en informatique, Université de Batna, 2002
- [35] Chetouani, A. (2010). Vers un système d'évaluation de la qualité d'image multi-critères (Doctoral dissertation, Paris; Université Paris-Nord-Paris XIII)
- [36] <https://www.mygreatlearning.com/blog/what-is-ridge-regression/>, 25/05/23.