

Vous trouverez la solution à la suite de tous les énoncés.

## Exercice 1

**Question 1 :** Soient  $A \in \mathbb{R}^{4 \times n}$ ,  $B \in \mathbb{R}^{n \times 4}$  et  $C \in \mathbb{R}^{n \times n}$  trois matrices,

- le produit  $ACB$  est défini quel que soit  $n$
- le produit  $BAC$  est défini quel que soit  $n$
- le produit  $BAC$  pour  $n = 4$
- le produit  $ABC$  pour  $n = 4$

**Question 2 :** Soit  $f : x \mapsto A\sigma(x)$  avec  $A \in \mathbb{R}^{6 \times 3}$

- admet 3 dérivées partielles
- admet 6 dérivées partielles
- admet  $3 \times 6$  dérivées partielles
- admet  $3 \times 6 \times 3$  dérivées partielles
- admet  $3 \times 6 \times 6$  dérivées partielles
- admet un nombre inconnu de dérivées partielles

**Question 3 :** Soit  $f : A \mapsto A\sigma(x)$  avec  $A \in \mathbb{R}^{6 \times 3}$

- admet 3 dérivées partielles
- admet 6 dérivées partielles
- admet  $3 \times 6$  dérivées partielles
- admet  $3 \times 6 \times 3$  dérivées partielles
- admet  $3 \times 6 \times 6$  dérivées partielles
- admet un nombre inconnu de dérivées partielles

**Question 4 :** Quelles propriétés sont vraies ?

- $f \circ g$  est croissante si et seulement si  $f$  est croissante et  $g$  est croissante
- $f : x \mapsto Ax$ , avec  $A \in \mathbb{R}^{2 \times 2}$  admet un minimum global
- $f : x \mapsto e^{-x^2}$  admet un maximum global
- $f : x \mapsto ax^2$  admet un minimum global

**Question 5 :** Soit  $X$  une variable aléatoire sur  $\mathbb{R}$

- $\mathbb{E}[X] = \int_{\mathbb{R}} f(x)dx$
- $\mathbb{E}[X] = \int_{\mathbb{R}} xf(x)dx$
- $\mathbb{E}[X] = \sum_{i=0}^{\mathbb{N}} \mathbb{P}(X = i)$
- $\mathbb{E}[X] = \sum_{i=0}^{\mathbb{N}} i\mathbb{P}(X = i)$

## Exercice 2 : prédire la fraude

Nous allons étudier les bases du modèle derrière la détection de fraude fiscale par imagerie satellitaire. Le modèle  $F$  traite des images de résolution  $R = 768 \times 768 \times 3$  et prédit un "masque" binaire, c'est-à-dire une matrice dont les valeurs sont dans  $[0; 1]$  de taille  $768 \times 768$ .

**Question 1 :** Donner l'expression de  $F$  de la forme  $F : ? \rightarrow ?$ .

**Question 2 :** Donner le nombre de dérivées partielles de  $F$ .

Afin d'entraîner notre modèle, nous avons besoin d'une fonction de coût  $\mathcal{L}$ . Proposons la fonction de coût suivante  $\mathcal{L} : (M_1, M_2) = \text{mIoU}(M_1, M_2)$  ou  $M_1 \in \{0; 1\}^{768 \times 768}$  et  $M_2 \in \{0; 1\}^{768 \times 768}$ . Le mIoU est l'intersection des masques divisée par leur union.

**Question 3 :** Pour calculer la mIoU, nous allons calculer l'intersection  $I : (M_1, M_2) \mapsto I(M_1, M_2) \in \mathbb{R}$  entre les deux masques. Proposer une formule pour calculer l'intersection entre deux masques binaires.

*indication : par exemple, pour calculer la taille de  $M_1$ , on pourrait utiliser la fonction  $f : M \mapsto \sum_i \sum_j M_{i,j}$*

**Question 4 :** Pour calculer la mIoU, nous allons calculer l'union  $U : (M_1, M_2) \mapsto U(M_1, M_2) \in \mathbb{R}$  entre les deux masques. Proposer une formule pour calculer l'union entre deux masques binaires.

À partir de maintenant, la mIoU est uniquement une fonction de  $M_1$ , autrement dit  $M_2$  est une constante.

**Question 5 :** La mIoU admet combien de dérivées partielles ?

**Question 6 :** Calculer les dérivées partielles de la mIoU.

Les masques utilisés dans la mIoU sont binaires, or les masques prédits par notre modèle ne sont pas binaires, mais dans  $[0; 1]$ . Pour convertir nos masques, nous allons utiliser la fonction  $t$

**Question 7 :** Avec  $t : M \mapsto \lfloor M \rfloor$  la fonction "arrondi au plus proche". Par exemple,  $t((0.1 \ 0.54 \ 0.98)) = (0 \ 1 \ 1)$ . Donner la jacobienne de  $t$ .

**Question 8 :** Peut-on optimiser  $F$  par descente de gradient avec les opérations suivantes  $\mathcal{L}(t(F(X)), Y)$  ?

## Exercice 2 (autre) : un peu de probabilité

Nous nous intéressons au problème suivant : prédire le salaire d'un salarié à partir de sa grille de performance accumulée sur 10 ans. Cette grille contient trois indicateurs, chacun représenté par un nombre réel.

**Question 1 :** Proposer une fonction  $f$  avec des paramètres pour résoudre le problème précédent.

*indication : la question suivante donne un exemple de réponse pour cette question (à ne pas copier à l'identique).*

**Question 2 :** On utilisera la fonction  $f : \begin{matrix} \mathbb{R}^3 & \rightarrow & \mathbb{R} \\ x = (x_1, x_2, x_3) & \mapsto & \text{relu}(Wx) \end{matrix}$ , donner les dimensions de  $W$  et son nombre de dérivées partielles.

**Question 3 :** Calculer les dérivées partielles de  $f$  par rapport à  $W$ .

**Question 4 :** Nous proposons la fonction de cout  $\mathcal{L}(x, y) = |x - y|$ . Calculer sa dérivée par rapport à  $x$ .

**Question 5 :** Appliquer la descente de gradient sur  $f$  avec un pas d'apprentissage  $\lambda = 1$ ,  $W_1$  vaut un partout,  $x$  vaut un partout et  $y$  vaut 1, sur 2 étapes.

**Question 6 :** Notre modèle est alors évalué sur 1200 salariés. Pour savoir si notre modèle est correct, nous considérons une prédiction comme "bonne" si elle est à moins de 100\$ du salaire réel. Nous obtenons une sensibilité de 0.9, une VPP de 0.9, une VPN de 0.95. Que vaut la spécificité ?

*rappel : sensibilité =  $\frac{TP}{TP+FN}$ , spécificité =  $\frac{TN}{TN+FP}$ , VPP =  $\frac{TP}{TP+FP}$  et VPN =  $\frac{TN}{TN+FN}$*

## Exercice 1

**Question 1 :** Soient  $A \in \mathbb{R}^{4 \times n}$ ,  $B \in \mathbb{R}^{n \times 4}$  et  $C \in \mathbb{R}^{n \times n}$  trois matrices,

- le produit  $ACB$  est défini quel que soit  $n$
- le produit  $BAC$  est défini quel que soit  $n$
- le produit  $BAC$  pour  $n = 4$
- le produit  $ABC$  pour  $n = 4$

**Question 2 :** Soit  $f : x \mapsto A\sigma(x)$  avec  $A \in \mathbb{R}^{6 \times 3}$

- admet 3 dérivées partielles
- admet 6 dérivées partielles
- admet  $3 \times 6$  dérivées partielles
- admet  $3 \times 6 \times 3$  dérivées partielles
- admet  $3 \times 6 \times 6$  dérivées partielles
- admet un nombre inconnu de dérivées partielles

**Question 3 :** Soit  $f : A \mapsto A\sigma(x)$  avec  $A \in \mathbb{R}^{6 \times 3}$

- admet 3 dérivées partielles
- admet 6 dérivées partielles
- admet  $3 \times 6$  dérivées partielles
- admet  $3 \times 6 \times 3$  dérivées partielles
- admet  $3 \times 6 \times 6$  dérivées partielles
- admet un nombre inconnu de dérivées partielles

**Question 4 :** Quelles propriétés sont vraies ?

- $f \circ g$  est croissante si et seulement si  $f$  est croissante et  $g$  est croissante
- $f : x \mapsto Ax$ , avec  $A \in \mathbb{R}^{2 \times 2}$  admet un minimum global
- $f : x \mapsto e^{-x^2}$  admet un maximum global
- $f : x \mapsto ax^2$  admet un minimum global

**Question 5 :** Soit  $X$  une variable aléatoire sur  $\mathbb{R}$

- $\mathbb{E}[X] = \int_{\mathbb{R}} f(x)dx$
- $\mathbb{E}[X] = \int_{\mathbb{R}} xf(x)dx$
- $\mathbb{E}[X] = \sum_{i=0}^{\mathbb{N}} \mathbb{P}(X = i)$
- $\mathbb{E}[X] = \sum_{i=0}^{\mathbb{N}} i\mathbb{P}(X = i)$

## Exercice 2 : prédire la fraude

Nous allons étudier les bases du modèle derrière la détection de fraude fiscale par imagerie satellitaire. Le modèle  $F$  traite des images de résolution  $R = 768 \times 768 \times 3$  et prédit un "masque" binaire, c'est-à-dire une matrice dont les valeurs sont dans  $[0; 1]$  de taille  $768 \times 768$ .

**Question 1 :** Donner l'expression de  $F$  de la forme  $F : ? \rightarrow ?$ .

$$F : \mathbb{R}^R \rightarrow [0; 1]^{768 \times 768}$$

$$F : \mathbb{R}^R \rightarrow \mathbb{R}^{768 \times 768}$$

$$F : \mathbb{R}^{768 \times 768 \times 3} \rightarrow \mathbb{R}^{768 \times 768}$$

**Question 2 :** Donner le nombre de dérivées partielles de  $F$ .

$F$  admet  $R$  entrées et  $768 \times 768$  sorties et donc  $R \times (768 \times 768)$  dérivées partielles. Par ailleurs, 1, 043, 677, 052, 928 (de tête bien évidemment).

Afin d'entraîner notre modèle, nous avons besoin d'une fonction de cout  $\mathcal{L}$ . Proposons la fonction de cout suivante  $\mathcal{L} : (M_1, M_2) = \text{mIoU}(M_1, M_2)$  ou  $M_1 \in \{0; 1\}^{768 \times 768}$  et  $M_2 \in \{0; 1\}^{768 \times 768}$ . Le mIoU est l'intersection des masques divisée par leur union.

**Question 3 :** Pour calculer la mIoU, nous allons calculer l'intersection  $I : (M_1, M_2) \mapsto I(M_1, M_2) \in \mathbb{R}$  entre les deux masques. Proposer une formule pour calculer l'intersection entre deux masques binaires.

L'intersection entre deux ensembles est le sous-ensemble des éléments appartenant aux deux ensembles. Nous pouvons donc partir sur la définition suivante

$$I(M_1, M_2) = \sum_i \sum_j 1 \text{ si element } i,j \text{ dans "M}_1\text{" et "M}_2\text{, et 0 sinon}$$

Cette "formule" peut se simplifier très facilement, en effet, dire que l'élément  $i, j$  est dans  $M_1$  est équivalent à dire  $(M_1)_{i,j} = 1$ , au contraire l'élément  $i, j$  n'est pas dans  $M_1$  est équivalent à dire  $(M_1)_{i,j} = 0$

$$I(M_1, M_2) = \sum_i \sum_j (M_1)_{i,j} (M_2)_{i,j}$$

**Question 4 :** Pour calculer la mIoU, nous allons calculer l'union  $U : (M_1, M_2) \mapsto U(M_1, M_2) \in \mathbb{R}$  entre les deux masques. Proposer une formule pour calculer l'union entre deux masques binaires. Pour calculer, l'union, nous allons utiliser la propriété suivante taille de  $U =$  taille de  $M_1 +$  taille de  $M_2 -$  taille de  $I$ . Donc, on obtient

$$U(M_1, M_2) = \sum_i \sum_j (M_1)_{i,j} + (M_2)_{i,j} - (M_1)_{i,j} (M_2)_{i,j}$$

À partir de maintenant, la mIoU est uniquement une fonction de  $M_1$ , autrement dit  $M_2$  est une constante.

**Question 5 :** La mIoU admet combien de dérivées partielles ?

La mIoU admet  $768 \times 768$  entrées et retourne un nombre. Cette fonction admet donc  $768 \times 768 \times 1$  dérivées partielles.

**Question 6 :** Calculer les dérivées partielles de la mIoU.

Les dérivées partielles de la mIoU sont de la forme

$$\begin{aligned} \frac{\partial \text{mIoU}}{\partial (M_1)_{i,j}}(M_1, M_2) &= \frac{\partial \frac{I(M_1, M_2)}{U(M_1, M_2)}}{\partial (M_1)_{i,j}} \\ &= \frac{\frac{\sum_i \sum_j (M_1)_{i,j} (M_2)_{i,j}}{\sum_i \sum_j (M_1)_{i,j} + (M_2)_{i,j} - (M_1)_{i,j} (M_2)_{i,j}}}{\partial (M_1)_{i,j}} \end{aligned}$$

Nous avons une dérivée de la forme  $\frac{f}{g}$ , nous allons donc calculer les dérivées partielles de "f" et "g".

$$\begin{cases} \frac{\partial I}{\partial (M_1)_{i,j}}(M_1, M_2) = (M_2)_{i,j} \\ \frac{\partial U}{\partial (M_1)_{i,j}}(M_1, M_2) = 1 - (M_2)_{i,j} \end{cases}$$

On obtient alors

$$\frac{\partial \text{mIoU}}{\partial (M_1)_{i,j}}(M_1, M_2) = \frac{(M_2)_{i,j} U(M_1, M_2) - (1 - (M_2)_{i,j}) I(M_1, M_2)}{U(M_1, M_2)^2} = \frac{(M_2)_{i,j}}{U(M_1, M_2)} - \frac{1 - (M_2)_{i,j}}{U(M_1, M_2)} \text{mIoU}(M_1, M_2)$$

Les masques utilisés dans la mIoU sont binaires, or les masques prédits par notre modèle ne sont pas binaires, mais dans  $[0; 1]$ . Pour convertir nos masques, nous allons utiliser la fonction  $t$

**Question 7 :** Avec  $t : M \mapsto \lfloor M \rfloor$  la fonction "arrondi au plus proche". Par exemple,  $t((0.1 \ 0.54 \ 0.98)) = (0 \ 1 \ 1)$ . Donner la jacobienne de  $t$ .

Cette fonction admet  $768 \times 768$  entrées et  $768 \times 768$  sorties. Ce qui nous donne beaucoup de dérivées partielles. Calculons une dérivée partielle quelconque

$$\frac{\partial t(M)_{i,j}}{\partial M_{k,l}} = \frac{\partial \lfloor M \rfloor_{i,j}}{\partial M_{k,l}} = 0$$

puisque la dérivée de la fonction arrondie est toujours zéro quand elle est définie.

**Question 8 :** Peut-on optimiser  $F$  par descente de gradient avec les opérations suivantes  $\mathcal{L}(t(F(X)), Y)$  ?

À cause de  $t$  les gradients seront tous nuls, on ne peut donc pas optimiser notre modèle par descente de gradient de cette manière.

## Exercice 2 (autre) : un peu de probabilité

Nous nous intéressons au problème suivant : prédire le salaire d'un salarié à partir de sa grille de performance accumulée sur 10 ans. Cette grille contient trois indicateurs, chacun représenté par un nombre réel.

**Question 1 :** Proposer une fonction  $f$  avec des paramètres pour résoudre le problème précédent.

$$\begin{aligned} f : \mathbb{R}^3 &\rightarrow \mathbb{R} \\ x = (x_1, x_2, x_3) &\mapsto \text{relu}W_2\sigma(W_1x) \\ f : \mathbb{R}^3 &\rightarrow \mathbb{R} \\ x = (x_1, x_2, x_3) &\mapsto \text{relu}W_2\sigma(W_1x + b_1) \\ f : \mathbb{R}^3 &\rightarrow \mathbb{R} \\ x = (x_1, x_2, x_3) &\mapsto \text{relu}(W_2(x + \text{relu}(W_1x))) \end{aligned}$$

*indication : la question suivante donne un exemple de réponse pour cette question (à ne pas copier à l'identique).*

**Question 2 :** On utilisera la fonction  $f : \mathbb{R}^3 \rightarrow \mathbb{R}$ ,  $x = (x_1, x_2, x_3) \mapsto \text{relu}(Wx)$ , donner les dimensions de  $W$  et son nombre de dérivées partielles.

La fonction  $f$  admet trois entrées et une sortie. Puisque  $x \in \mathbb{R}^3$  et que nous multiplions  $W$  et  $x$ ,  $W$  admet nécessairement trois colonnes. De plus, puisque  $Wx \in \mathbb{R}$ ,  $W$  admet nécessairement une seule ligne. Donc  $W \in \mathbb{R}^{1 \times 3}$ .

De plus,  $f$  admet  $3 \times 1$  dérivées partielles.

**Question 3 :** Calculer les dérivées partielles de  $f$  par rapport à  $W$ .

Les dérivées partielles de  $f$  sont données par

$$\begin{aligned} \frac{\partial f(W)}{\partial W_{1,i}} &= \frac{\partial \text{relu}(Wx)}{\partial W_{1,i}} \\ &= \frac{\partial \text{relu}(W_{1,1}x_1 + W_{1,2}x_2 + W_{1,3}x_3)}{\partial W_{1,i}} \end{aligned}$$

Nous avons une composée de fonction.

$$\begin{cases} \frac{\partial \text{relu}(x)}{\partial x} = \mathbb{1}_{x>0} \\ \frac{\partial \text{relu}(W_{1,1}x_1 + W_{1,2}x_2 + W_{1,3}x_3)}{\partial W_{1,i}} = x_i \end{cases}$$

En utilisant la chain rule, nous obtenons

$$\frac{\partial f(W)}{\partial W_{1,i}} = \mathbb{1}_{Wx>0} \times x_i$$

**Question 4 :** Nous proposons la fonction de cout  $\mathcal{L}(x, y) = |x - y|$ . Calculer sa dérivée par rapport à  $x$ .

$$\frac{\partial |x - y|}{\partial x} = \begin{cases} 1 & \text{si } x > y \\ -1 & \text{sinon} \end{cases}$$

**Question 5 :** Appliquer la descente de gradient sur  $f$  avec un pas d'apprentissage  $\lambda = 1$ ,  $W_1$  vaut un partout,  $x$  vaut un partout et  $y$  vaut un, sur 2 étapes.

Nous allons calculer les termes  $W_2$  et  $W_3$  par descente de gradient :

$$W_n = W_{n-1} - \lambda J_{\mathcal{L} \circ f}(W_{n-1})$$

Dans notre cas, on obtient

$$W_n = W_{n-1} - 1 \times \begin{cases} 1 & \text{si } \text{relu}(W_{n-1}x) > y \\ -1 & \text{sinon} \end{cases} \quad \mathbb{1}_{W_{n-1}x>0} \times (x_1 \quad x_2 \quad x_3)$$

Nous obtenons alors

$$\begin{aligned}
 W_1 &= (1 \quad 1 \quad 1) \\
 W_2 &= W_1 - \begin{cases} 1 \text{ si } \text{relu}(W_1 x) > y \\ -1 \text{ sinon} \end{cases} \mathbb{1}_{W_1 x > 0} \times (x_1 \quad x_2 \quad x_3) \\
 &= W_1 - \begin{cases} 1 \text{ si } 6 > 1 \\ -1 \text{ sinon} \end{cases} \mathbb{1}_{6 > 0} \times (1 \quad 1 \quad 1) \\
 &= W_1 - 1 \times 1 \times (1 \quad 1 \quad 1) \\
 &= (0 \quad 0 \quad 0) \\
 W_3 &= W_2 - \begin{cases} 1 \text{ si } \text{relu}(W_2 x) > y \\ -1 \text{ sinon} \end{cases} \mathbb{1}_{W_2 x > 0} \times (x_1 \quad x_2 \quad x_3) \\
 &= W_2 - \begin{cases} 1 \text{ si } 0 > 1 \\ -1 \text{ sinon} \end{cases} \mathbb{1}_{0 > 0} \times (1 \quad 1 \quad 1) \\
 &= W_2 - (-1) \times 0 \times (1 \quad 1 \quad 1) \\
 &= (0 \quad 0 \quad 0)
 \end{aligned}$$

**Question 6 :** Notre modèle est alors évalué sur 1200 salariés. Pour savoir si notre modèle est correct, nous considérons une prédiction comme "bonne" si elle est à moins de 100\$ du salaire réel. Nous obtenons une sensibilité de 0.9, une VPP de 0.9, une VPN de 0.95. Que vaut la spécificité ?

L'énoncé nous donne le système d'équation suivant

$$\begin{cases}
 \text{TP} + \text{FP} + \text{TN} + \text{FN} = 1200 \\
 \text{sensibilite} = \frac{\text{TP}}{\text{TP} + \text{FN}} = 0.9 \\
 \text{VPP} = \frac{\text{TP}}{\text{TP} + \text{FP}} = 0.9 \\
 \text{VPN} = \frac{\text{TN}}{\text{TN} + \text{FN}} = 0.95
 \end{cases}$$

Voici une façon de résoudre ce système

$$\begin{cases}
 \text{TP} + \text{FP} + \text{TN} + \text{FN} = 1200 \\
 0.1\text{TP} = 0.9\text{FN} \\
 0.1\text{TP} = 0.9\text{FP} \\
 0.05\text{TN} = 0.95\text{FN}
 \end{cases}$$

$$\begin{cases}
 \text{TP} + \text{FP} + \text{TN} + \text{FN} = 1200 \\
 \text{TP} = 9\text{FN} \\
 \text{TP} = 9\text{FP} \\
 \text{TN} = 19\text{FN}
 \end{cases}$$

$$\begin{cases}
 9\text{FN} + \text{FN} + 19\text{FN} + \text{FN} = 1200 \\
 \text{TP} = 9\text{FN} \\
 \text{TP} = 9\text{FP} \\
 \text{TN} = 19\text{FN}
 \end{cases}$$

$$\begin{cases}
 \text{FN} = 40 \\
 \text{TP} = 360 \\
 \text{FP} = 40 \\
 \text{TN} = 760
 \end{cases}$$

On en déduit

$$\text{specificite} = \frac{\text{TN}}{\text{TN} + \text{FP}} = \frac{760}{800} = 0.95$$