

# Intelligence Artificielle dans l'Élaboration de Règles de Dimensionnement de Structures Mécaniques, Appliquée aux Équipements sous Pression suivant le CODAP<sup>®</sup>

Philippe AMUZUGA<sup>1</sup>, Jean-Louis IWANIACK<sup>2</sup>

<sup>1</sup> CETIM - Centre Technique des Industries Mécaniques, 7 Rue de la Presse, 42000 Saint-Étienne, France, philippe.amuzuga@cetim.fr

<sup>2</sup> CETIM, 52 Avenue Félix Louat, 60300 Senlis, France, jeanlouis.iwaniack@cetim.fr

---

## Résumé — Comment le Machine Learning peut-il optimiser les critères d'admissibilité et développer de nouvelles règles analytiques pour l'évaluation de la résistance des structures mécaniques ?

Cette étude traite de cette question en montrant comment la combinaison de simulations par éléments finis (EF) et de Machine Learning (ML) a permis d'optimiser les règles actuelles du CODAP<sup>®</sup> pour le dimensionnement du raccordement du fond d'un appareil posé sur jupe et d'élaborer de nouvelles règles de vérification de la tenue de ligaments entre tubulures voisines dans des régions critiques d'équipements sous pression (ESP). L'approche s'appuie sur un modèle éléments finis paramétré (Abaqus-Python), une campagne de simulation d'une matrice de configurations géométriques variées, et enfin un algorithme de Régression Multifactorielle Récursive (RMR) développé sur la base de la bibliothèque Scikit-Learn. Les résultats mettent en évidence qu'environ un tiers des raccordements classés défaillants par le CODAP<sup>®</sup> sont en réalité résistants lorsque les résultats EF sont pris comme référence. L'étude a permis non seulement de produire des règles d'expressions littérales permettant une interprétabilité, mais aussi une meilleure adéquation entre les résultats du CODAP<sup>®</sup> et ceux obtenus par EF. Cet article présente une synthèse des travaux réalisés, mettant en lumière les applications potentielles de ces nouvelles techniques d'intelligence artificielle dans l'industrie mécanique.

**Mots clés** — Machine Learning, Éléments Finis, CODAP<sup>®</sup>, Régression Multifactorielle Récursive.

---

## 1 Introduction

Les équipements sous pression (ESP) sont omniprésents et essentiels dans les industries chimiques et énergétiques. Les enceintes sont principalement exploitées non seulement pour le stockage et le traitement des fluides, mais contribuent aussi au contrôle de variables macroscopiques comme le débit, la pression, la température, etc., avant l'acheminement via la tuyauterie, ce qui exige une conception rigoureuse pour la sécurité de ces opérations et le fonctionnement en service. Les directives de conception, qui incluent le chargement, les conditions opérationnelles et les configurations géométriques, sont encadrées par des normes et des codes de construction spécifiques, tels que le CODAP<sup>®</sup>, qui établissent les pratiques standard de conception, de fabrication et d'inspection afin de minimiser les risques de rupture catastrophique [1, 2, 3, 4, 5]. Ces codes adoptent des coefficients de sécurité qui, tout en étant prudents, doivent éviter une approche excessivement conservatrice pouvant conduire à un surdimensionnement inutile et coûteux des équipements.

Cet article expose uniquement la partie de l'étude qui traite de l'optimisation des règles de dimensionnement CODAP<sup>®</sup>, spécifiquement pour les raccordements de type C dans les appareils montés sur jupe (C9.7.2.1-2), comme l'illustre la Figure 1.

La procédure actuelle, conformément à la règle C9.7.5, évalue les contraintes de membrane et de flexion via trois coupes à la jonction jupe-fond, générant neuf valeurs de contraintes à partir de sept variables de charge, à l'aide d'une matrice de coefficients [9 x 7]. Ces coefficients dérivent de quatre coefficients intermédiaires sans dimension obtenus par rapport aux paramètres géométriques. Cependant, ces règles, qui remontent aux années 80 et sont basées sur la règle RKF BR-K4 [4], ont été élaborées à partir d'un lissage des résultats de calculs numériques de cette époque. Elles n'intègrent donc pas les progrès en modélisation et simulation numérique. Réviser ces formules est nécessaire pour ajuster les résultats

obtenus via le CODAP<sup>®</sup> à ceux qu'on obtiendrait en pratique avec les simulations éléments finis afin de réduire les coefficients de sécurité au niveau de justesse des analyses. D'où l'usage du Machine Learning [6] pour effectuer cet ajustement.




FIGURE 1 – Illustration des sections critiques de la zone de raccordement jupe-appareil.

## 2 Méthodologie

La Figure 2 présente l'enchaînement des opérations conduisant à l'optimisation des règles de dimensionnement du raccordement jupe-appareil du CODAP<sup>®</sup>. La démarche d'élaboration des nouvelles règles analytiques pour ajuster les contraintes CODAP<sup>®</sup> sur celles des EF peut être synthétisée comme suit :

1. Définition de la matrice contenant des configurations à traiter : Les géométries et chargements sont des cas représentatifs des équipements courants.
2. Campagne de simulations EF et de calculs suivant CODAP<sup>®</sup> : Détermination des valeurs des contraintes de membrane et de flexion dans le sens longitudinal et dans le sens circonférentiel pour les trois sections les plus critiques du raccordement.
3. Analyse des résultats obtenus via les deux modes de calculs :
  - (a) Calcul de l'admissibilité des contraintes au raccordement.
  - (b) Construction d'un algorithme d'apprentissage automatique avec Scikit-Learn [6] pour l'établissement des formules de correction.

Le module de calcul EF a été développé en deux phases. La première phase consiste à créer un modèle sur Abaqus CAE, permettant de paramétrer le problème avec des variables liées aux dimensions géométriques et aux propriétés des matériaux. La deuxième phase développe un script Python généré à partir du fichier journal d'Abaqus, définissant les zones de chargement et les conditions aux limites. Les composants sont modélisés en 3D en utilisant les données de la norme NF E 81-103 [7], avec un maillage raffiné près des zones critiques et des calculs en statique dans le domaine élastique linéaire pour de l'acier P265GH homogène et isotrope.

Les résultats des simulations EF et des calculs selon le CODAP<sup>®</sup> sont ensuite comparés afin de déterminer l'admissibilité des contraintes pour chaque section critique. Trois critères d'admissibilité sont calculés pour vérifier que les contraintes restent en deçà de limites prédéfinies, assurant ainsi la conformité des sections critiques 1, 2 et 3 du raccordement.

La Figure 3 détaille la construction du module de Machine Learning. La première étape concerne la préparation et la normalisation des données pour l'entraînement de l'algorithme. Les données sont divisées en groupes pour l'entraînement, la validation et le test, permettant ainsi de choisir les hyperparamètres optimaux et d'évaluer la performance descriptive et prédictive du modèle.




FIGURE 2 – Organigramme des étapes d’élaboration des nouvelles formules de calcul des contraintes dans le raccordement.




FIGURE 3 – Présentation du module de Machine Learning.

La deuxième étape implique le traitement des données par l’algorithme d’entraînement. Cet algorithme utilise un processus de classement et d’élimination récursive des variables, sélectionnant celles qui maximisent la performance de l’estimateur [9]. Ce processus garantit que la sélection des variables n’est pas arbitraire mais basée sur leur performance au regard d’indicateurs d’adéquation statistique, évitant ainsi le surajustement et maintenant l’équilibre optimal entre biais et variance.

Après la sélection des variables et l’identification des valeurs des hyper-paramètres, la troisième étape consiste à inspecter les coefficients de l’estimateur. Il s’agit des coefficients  $c_i, 0 \leq i \leq 7$  permettant d’écrire les formules d’ajustement des contraintes partielles. Cette étape permet d’évaluer les prédictions de l’estimateur sur les données du groupe de test. À l’issue de cette évaluation, les formules d’ajustement sont appliquées afin de générer des courbes de comparaison des contraintes corrigées ainsi que les écarts résiduels sur l’ensemble des données de ce groupe de test.

### 3 Résultats

La Figure 4 présente la modélisation et le résultat de la simulation EF d’un exemple de raccordement jupe-appareil. Les résultats indiquent que la contrainte maximale de Von Mises est localisée dans la zone critique du raccordement. Il est important de noter que cet article se concentre spécifiquement sur les

résultats concernant la contrainte longitudinale de flexion de la section critique 2.

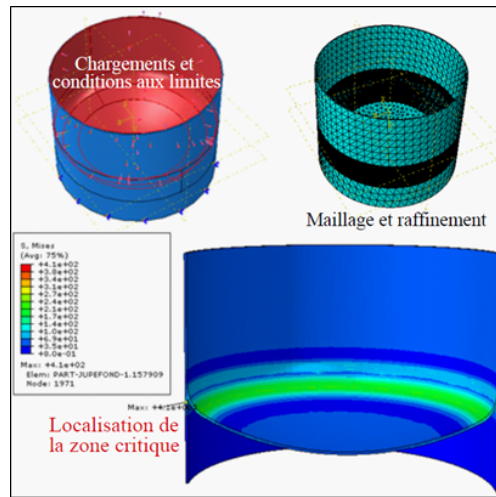
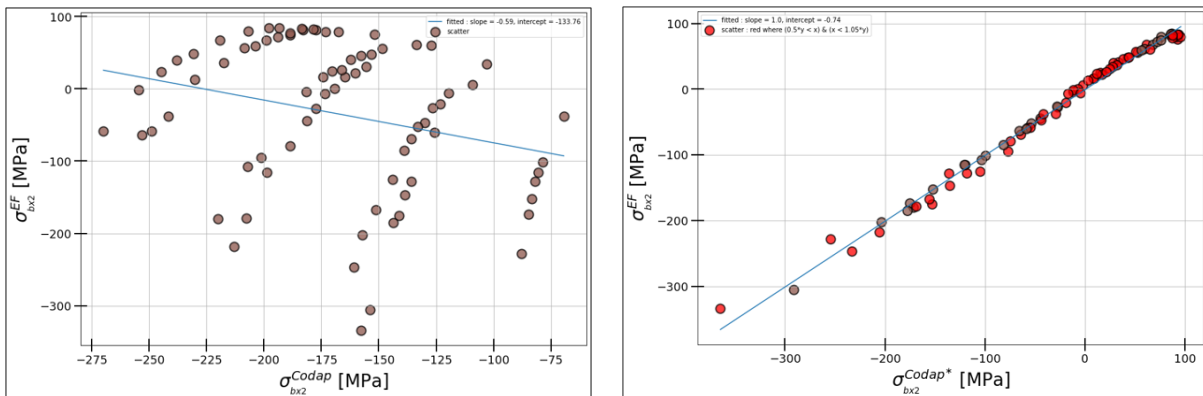


FIGURE 4 – Modélisation et simulation EF du raccordement jupe-appareil.

La partie gauche de la Figure 5 illustre les valeurs de la contrainte longitudinale de flexion de la section 2 obtenues par simulation EF par rapport à celles calculées selon le CODAP<sup>®</sup>. On remarque une corrélation globalement faible, avec la formation de groupes distincts où la relation non linéaire entre les résultats EF et le CODAP<sup>®</sup> est plus prononcée. De surcroît, le signe du coefficient de corrélation s’inverse lorsqu’on analyse l’ensemble des données par rapport à l’analyse des groupes séparés, mettant en évidence un paradoxe de Simpson [8]. Cependant, le graphique de droite démontre une corrélation linéaire forte entre les valeurs obtenues par EF et celles ajustées par l’algorithme d’intelligence artificielle.



(a) Contrainte longitudinale de flexion obtenue par CODAP<sup>®</sup> comparée avec celle obtenue par EF.

(b) Valeurs ajustées par l’algorithme d’intelligence artificielle comparée avec celle obtenue par EF.

FIGURE 5 – Comparaison des valeurs de contrainte longitudinale de flexion de la section 2 obtenues par simulation EF et par l’ancienne règle CODAP<sup>®</sup> à gauche (a), et ajustées par l’algorithme d’intelligence artificielle à droite (b).

Le Tableau 1 présente la méthode de correction de la contrainte longitudinale de flexion dans la section critique 2.

La partie gauche de la Figure 6 montre la distribution des écarts entre les contraintes longitudinales de flexion de la section 2 obtenues par simulation EF et par les calculs CODAP<sup>®</sup> après correction. On observe que l’algorithme de Machine Learning génère principalement de petites erreurs. La partie droite de la Figure 6 présente la dispersion de ces écarts par rapport aux valeurs attendues. L’estimateur commet une erreur significative pour une seule configuration, mais cette dernière concerne une valeur de contrainte presque nulle, ce qui a un impact marginal sur la performance globale de l’algorithme, avec une réelle conséquence négligeable sur l’application industrielle. La performance de l’estimateur est évaluée selon le pourcentage de prédictions se situant dans une marge d’erreur de plus ou moins 5% par rapport aux valeurs cibles.

TABLE 1 – Méthode de correction de la contrainte longitudinale de flexion dans la section critique 2.

Normalisation par centrage et réduction						
$\tilde{D}e = \frac{De - D_e^{(m)}}{D_e^{(sdt)}}$	$\tilde{E} = \frac{E - E^{(m)}}{E^{(sdt)}}$	$\tilde{h} = \frac{h - h^{(m)}}{h^{(sdt)}}$	$\tilde{H} = \frac{H - H^{(m)}}{H^{(sdt)}}$	$\tilde{p} = \frac{p - p^{(m)}}{p^{(sdt)}}$	$\tilde{f} = \frac{f - f^{(m)}}{f^{(sdt)}}$	$\tilde{\sigma}_{bx2} = \frac{\sigma_{bx2} - \sigma_{bx2}^{(m)}}{\sigma_{bx2}^{(sdt)}}$
Valeur des constantes de normalisation						
$D_e^{(m)} = 1968.965517$	$D_e^{(sdt)} = 675.994005$	$E^{(m)} = 22.775862$	$E^{(sdt)} = 9.861180$	$h^{(m)} = 79.396552$	$h^{(sdt)} = 22.668480$	$H^{(m)} = 370.517241$
$H^{(sdt)} = 129.296937$	$p^{(m)} = 2.896552$	$p^{(sdt)} = 0.994635$	$f^{(m)} = -60.693069$	$f^{(sdt)} = 21.188008$	$\sigma_{bx2}^{(m)} = -167.031948$	$\sigma_{bx2}^{(sdt)} = 46.504330$
Formules de correction de la contrainte						
$\sigma_{bx2}^* = c_0 + c_1 \tilde{D}e + c_2 \tilde{E} + c_3 \tilde{h} + c_4 \tilde{H} + c_5 \tilde{p} + c_6 \tilde{f} + c_7 \tilde{\sigma}_{bx2}$						
Valeur des coefficients de l'ajustement						
$c_0 = -32.774017$	$c_1 = 795.318084$	$c_2 = -66.037898$	$c_3 = 10.125250$	$c_4 = -820.894722$	$c_5 = -31.706060$	$c_6 = 125.423678$
				$c_7 = -163.978234$		




FIGURE 6 – Analyse des écarts entre les prédictions de l'algorithme de Machine Learning et les valeurs cibles : distribution des écarts à gauche, dispersion des écarts en fonction des valeurs attendues à droite.

## 4 Discussion

Une analyse de contingence a été réalisée pour comparer qualitativement et quantitativement les différences entre les résultats obtenus avec les règles actuelles du CODAP<sup>®</sup> et ceux issus des calculs EF. L'objectif était de déterminer si les dimensions prescrites par le CODAP<sup>®</sup> sont plus conservatrices par rapport aux résultats EF et, si tel est le cas, d'évaluer l'ampleur de l'écart pour décider si une révision des règles du CODAP<sup>®</sup> est justifiée.

Le Tableau 2 indique que parmi 76 configurations, environ 11% ont été classées comme « résistantes » selon le CODAP<sup>®</sup>, tandis que 39% l'ont été selon les calculs EF. Inversement, 89% ont été jugées « défaillantes » par le CODAP<sup>®</sup> contre 61% par l'EF. L'analyse conjointe révèle que le CODAP<sup>®</sup> identifie faussement comme « défaillantes » environ 33% des configurations et incorrectement comme « résistantes » 4% des configurations. Cette tendance marque le CODAP<sup>®</sup> comme étant conservatif par rapport à l'EF, avec une proportion notablement élevée qui souligne la nécessité d'une mise à jour des règles en vigueur.

TABLE 2 – Tableau de contingence <sup>1</sup> : Évaluation des résultats CODAP comparés aux EF

		Variable de référence : Admissibilité EF			
		Résistant : R = 30	Défaillant : D = 46	Prévalence de Résistant : R/N = 39%	Prévalence de Défaillant : D/N = 61%
Variable évaluée : Admissibilité CODAP	Résistant : r = 8	Vrai Positif : VP = 5 (Classification correcte <sup>2</sup> )	Faux Positif : FP = 3 (Erreur de type I <sup>3</sup> )	Valeur Prédictive Positive (Précision <sup>4</sup> ) : VP/(VP+FP) = 63%	
	Défaillant : d = 68	Faux Négatif : FN = 25 (Erreur de type II <sup>5</sup> )	Vrai Négatif : VN = 43 (Classification correcte <sup>6</sup> )	Valeur Prédictive Négative (Fidélité) : VN/(FN+VN) = 63%	
	Effectif total : N = 76	Sensibilité : VP/(VP+FN) = 17%	Spécificité : VN/(FP+FN) = 93%	Justesse (Exactitude) : (VP+VN)/N = 63%	

L'analyse de contingence fournit des mesures de performance telles que la prévalence, la sensibilité, la spécificité, ainsi que les valeurs prédictives positives et négatives. Ces indicateurs sont dérivés des vrais positifs (VP), faux positifs (FP), faux négatifs (FN) et vrais négatifs (VN), avec les résultats des calculs EF servant de référence. Selon le tableau ci-dessus, l'admissibilité déterminée par le CODAP<sup>®</sup> a une sensibilité de 17%, indiquant une probabilité de 17% de reconnaître correctement un dimensionnement jugé « résistant » par l'EF. En revanche, le CODAP<sup>®</sup> a une spécificité élevée pour identifier les dimensionnements « défaillants », avec une probabilité de 93%. Les valeurs prédictives, tant positive que négative, sont d'environ 63%, ce qui signale une probabilité égale que le CODAP<sup>®</sup> classe correctement les dimensionnements comme « résistants » ou « défaillants ».

#### 4.1 Matrice de confusion après l'optimisation des règles

Le Tableau 3 présente une évaluation des résultats après l'optimisation des règles du CODAP<sup>®</sup> comparés aux simulations EF. L'amélioration des indicateurs de comparaison est significative, indiquant une concordance accrue entre les résultats des calculs effectués avec les nouvelles formules de la section C9.7 et ceux obtenus par l'EF.

TABLE 3 – Tableau de contingence : Évaluation des résultats CODAP optimisés comparés aux EF

		Variable de référence : Admissibilité EF			
		Résistant : R = 30	Défaillant : D = 46	Prévalence de Résistant : R/N = 39%	Prévalence de Défaillant : D/N = 61%
Variable évaluée : Admissibilité CODAP optimisé	Résistant : r = 31	Vrai Positif : VP = 30 (Classification correcte)	Faux Positif : FP = 1 (Erreur de type I)	Valeur Prédictive Positive (Précision) : VP/(VP+FP) = 97%	
	Défaillant : d = 45	Faux Négatif : FN = 0 (Erreur de type II)	Vrai Négatif : VN = 45 (Classification correcte)	Valeur Prédictive Négative (Fidélité) : VN/(FN+VN) = 100%	
	Effectif total : N = 76	Sensibilité : VP/(VP+FN) = 100%	Spécificité : VN/(FP+FN) = 98%	Justesse (Exactitude) : (VP+VN)/N = 63%	

Les valeurs de la matrice de confusion, notamment les vrais positifs (VP) et vrais négatifs (VN), montrent que les règles optimisées du CODAP<sup>®</sup> ont une sensibilité et une spécificité presque parfaites, avec une sensibilité de 100% et une spécificité de 98%. La valeur prédictive positive (VPP) et la valeur prédictive négative (VPN) sont respectivement de 97% et 100%, ce qui démontre une nette supériorité des règles optimisées par rapport à l'ancienne version du CODAP<sup>®</sup>. Ces résultats traduisent une justesse globale remarquable des prédictions après l'optimisation, avec une exactitude de 99%.

1. Matrice de confusion utilisée en théorie de la détection pour évaluer la validité et la fiabilité d'une méthode de diagnostic ou de différenciation de deux états, généralement plus simple à mettre en place, en la comparant à une méthode de référence qui est généralement plus complexe. Elle est très appliquée en médecine notamment en épidémiologie pour évaluer des tests de dépistage.

2. Prise de décision de conserver les dimensions.

3. Le risque  $\alpha$  est le niveau acceptable de l'erreur du 1<sup>er</sup> espèce, fixée arbitrairement en fonction de la dangerosité des conséquences liées à une mauvaise prise de décision.

4. Voir d'autres métriques comme le Recall et le F1-score.

5. Le risque  $\beta$  est le niveau acceptable de l'erreur du 2<sup>e</sup> espèce, fixée arbitrairement en fonction de la dangerosité des conséquences liées à une mauvaise prise de décision.

6. Prise de décision d'augmentation de l'épaisseur du fond et de reprise des calculs de vérification de l'admissibilité.

## 5 Conclusion

Cette étude a révélé que la règle de dimensionnement actuelle pour les raccords jupe-fond du CODAP® tend à surévaluer les risques, entraînant le rejet d'un nombre significatif de conceptions qui seraient jugées résistantes par les simulations EF. Précisément, environ un tiers des configurations testées sont classées comme « défailtantes » par le CODAP®, alors qu'elles sont considérées comme « résistantes » lorsqu'évaluées par EF. Cette constatation qualifie le CODAP® de conservateur par rapport aux méthodes EF et souligne la nécessité d'une révision des formules utilisées.

Les analyses statistiques approfondies ont permis de mesurer la performance du dimensionnement selon les règles actuelles du CODAP®. On note notamment une sensibilité de 17%, indiquant que le CODAP® reconnaît correctement une proportion limitée de conceptions admissibles. En outre, la valeur prédictive de ces règles est estimée à 63%.

L'application de l'algorithme de Machine Learning a démontré son efficacité pour formuler des relations explicites et interprétables afin de corriger la règle de dimensionnement de la jonction jupe-fond des appareils verticaux. L'ajustement ainsi obtenu entre les résultats du CODAP® et ceux des simulations EF présage d'une avancée significative vers des normes de conception plus précises et économiquement avantageuses.

## Références

- [1] Codes ASME. *American Society of Mechanical Engineers*.
- [2] 2014/68/UE. *DESP Directive européenne équipements sous pression*.
- [3] EN 13445-3. *Norme européenne pour la construction des équipements sous pression*, 2009.
- [4] RKF BR-K4. *Dimensionnement des jupes de colonnes*, 1981.
- [5] Division 2. *CODAP® Code de construction des appareils à pression non soumis à la flamme*, 2015.
- [6] scikit-learn. *machine learning in Python — scikit-learn 0.24.2 documentation*. Disponible sur : <https://scikit-learn.org/stable/index.html> (consulté le 29 août 2021).
- [7] NF E81-103 - Décembre 1997. *Fonds bombés - Fonds elliptiques - Dimensions*. Disponible sur : <https://www.boutique.afnor.org/norme/nf-e81-103/fonds-bombes-fonds-elliptiques-ell-dimensions/article/759657/fa012103> (consulté le 29 août 2021).
- [8] E. H. Simpson. *The interpretation of interaction in contingency tables*, J. R. Stat. Soc. Ser. B Methodol., vol. 13, no 2, p. 238-241, 1951.
- [9] sklearn.feature\_selection.RFECV. *scikit-learn 0.24.2 documentation*. Disponible sur : [https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_selection.RFECV.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.RFECV.html) (consulté le 29 août 2021).
- [10] C.-I. Chang. *Statistical detection theory approach to hyperspectral image classification*, IEEE Trans. Geosci. Remote Sens., vol. 57, no 4, p. 2057-2074, 2018.