

Beyond the Classical Copula : Artificial Intelligence Methods and Neural Copulas for Modeling Reserve Dependence in Non-Life Insurance

Au-delà de la Copule Classique : Modèles d'Intelligence Artificielle et Copules Neuronales pour la Modélisation de la Dépendance des Provisions en Assurance Non-Vie

Hajar ETTAYA^{#1}, Tarek ZARI^{*2}

*[#]Laboratoire de Modélisation Appliquée en Économie et Gestion, Université Hassan II
Casablanca, Maroc*

¹hajarettaya@gmail.com

²profzari@gmail.com

Abstract— Traditional copulas, although they have revolutionized dependence modeling by separating marginal structures from joint structures, present significant limitations in non-life insurance, where technical reserves (IBNR and RBNS) across multiple lines of business exhibit complex, asymmetric dependencies that intensify in the tail during extreme events (natural catastrophes, claims inflation, regulatory shocks). Through a critical literature review, this paper examines to what extent machine learning models and neural copulas can overcome these limitations for modeling reserve dependence. We detail the mathematical foundations and learning mechanisms of the main neural architectures applied to copulas IGNIS parametric estimation networks, GARCH-RBM models, deep neural copulas, copula-nested spectral kernel networks as well as reserving-specific neural approaches such as the neural Chain-Ladder, DeepTriangle, and its multi-line extension. A structured analytical comparison, based exclusively on results reported in the literature and explicitly referenced, highlights the trade-offs between expressive flexibility, interpretability, theoretical guarantees, and computational cost. We conclude that hybridization between actuarial rigor and the representational power of neural networks constitutes the most promising path for modeling complex dependencies in non-life reserving, subject to rigorous empirical validation on real data.

Keywords— neural copulas, machine learning, non-life reserving, IBNR reserves, development triangles, dependence structures.

Résumé— Les copules traditionnelles, bien qu'ayant révolutionné la modélisation des dépendances en séparant les structures marginales des structures conjointes, présentent des limites importantes en assurance non-vie, où les provisions techniques (réserves IBNyR et IBNeR) entre plusieurs lignes d'affaires exhibent des dépendances complexes (catastrophes naturelles et inflation des sinistres...). Cet article examine, à travers une revue de la littérature, dans quelle mesure les modèles d'apprentissage automatique et les copules neuronales peuvent surmonter ces limites pour la modélisation de la dépendance des réserves. Nous détaillons les fondements mathématiques et les mécanismes d'apprentissage des principales architectures neuronales appliquées aux copules réseaux d'estimation paramétrique IGNIS, modèles GARCH-RBM, copules neuronales profondes, réseaux à noyaux spectraux imbriqués de copules ainsi que des approches neuronales dédiées au provisionnement telles que le Chain-Ladder neuronal, DeepTriangle et son extension multi-lignes.

Une comparaison analytique structurée, fondée exclusivement sur les résultats rapportés dans la littérature et explicitement référencés, Cette comparaison met en évidence un compromis central : les modèles neuronaux gagnent en flexibilité ils peuvent représenter des formes de dépendance que les copules classiques ne peuvent pas reproduire — mais perdent en interprétabilité, en garanties théoriques établies, et demandent davantage de ressources de calcul. Nous concluons que la meilleure voie n'est pas de remplacer les copules classiques par les réseaux de neurones, mais de combiner les deux : garder la rigueur et la transparence de l'approche actuarielle traditionnelle, tout en exploitant la capacité des réseaux de neurones à capter des structures de dépendance plus complexes. Cette approche hybride reste cependant à valider sur des données réelles avant d'être adoptée en pratique.

Mots clés—copules neuronales, apprentissage automatique, provisionnement non-vie, réserves IBNyR & IBNeR, triangles de développement, structures de dépendance.

I. INTRODUCTION

La modélisation des dépendances entre variables aléatoires constitue un défi central en actuariat non-vie. Lorsqu'un assureur doit estimer ses provisions techniques pour sinistres survenus mais non réglés (IBNeR) ou survenus mais non encore déclarés (IBNyR), il ne peut se contenter de modéliser chaque ligne d'affaires (automobile, responsabilité civile, dommages aux biens) de manière isolée. Charpentier et Pigeon [15] distinguent à cet égard les méthodes macro-niveau, fondées sur l'agrégation des données en triangles de développement, des méthodes micro-niveau, qui exploitent l'information au niveau du sinistre individuel, cette distinction structure largement les approches que nous présentons dans cet article, les méthodes neuronales se situant souvent à l'intersection des deux logiques. Les sinistres de différentes branches partagent souvent des facteurs communs inflation des coûts de réparation, catastrophes naturelles, évolutions réglementaires ou jurisprudentielles qui créent une dépendance entre les triangles de développement, et donc entre les réserves correspondantes. Ignorer cette dépendance conduit à sous-estimer la variabilité du besoin global en provisions.

Depuis leur introduction par Sklar, les copules ont apporté une avancée majeure en permettant de découpler la modélisation des distributions marginales de celle de la structure de dépendance jointe [7]. Cette propriété a fait des copules un outil privilégié en actuariat non-vie, où elles ont été appliquées avec succès à la modélisation conjointe des délais de déclaration et de règlement pour le calcul des réserves IBNR [1], ainsi qu'à la dépendance spatiale entre sinistres consécutifs à un même événement climatique [2].

Cependant, les copules paramétriques traditionnelles qu'elles soient de la famille elliptique (Gaussienne, Student) ou archimédienne (Clayton, Gumbel, Frank, Joe) reposent sur des hypothèses restrictives quant à la forme de la dépendance. Par exemple, la copule de Clayton capture une dépendance asymétrique dans la queue inférieure, tandis que celle de Gumbel modélise une dépendance dans la queue supérieure, mais aucune des deux ne peut représenter simultanément un renforcement de la dépendance dans les deux queues, comme cela s'observe lorsque plusieurs lignes d'affaires sont conjointement affectées par un choc extrême. De plus, les copules traditionnelles peinent à s'adapter à un portefeuille comportant de nombreuses lignes d'affaires en raison de la dimensionnalité.

Dans ce contexte émergent les modèles d'apprentissage automatique appliqués à la fois aux copules et au provisionnement lui-même. D'un côté, des architectures neuronales générales IGNIS, copules neuronales profondes, GARCH-RBM, CokeNet, COPNN promettent de surmonter les limites des copules classiques en apprenant directement des structures de dépendance complexes à partir des données [3],[6], [13]. Ainsi, des modèles spécifiquement conçus pour le provisionnement DeepTriangle [9], le Chain-Ladder neuronal de Wüthrich [8], et leurs extensions multi-lignes [10] intègrent des réseaux de neurones directement dans le processus de projection des triangles de développement. Cet article vise à répondre à la question suivante : Dans quelle mesure les modèles d'apprentissage automatique et les copules neuronales peuvent-ils saisir des structures de dépendance entre réserves de sinistres non-vie que les copules traditionnelles ne peuvent pas reproduire ?

Cette problématique revêt une importance particulière pour les marchés d'assurance en développement, tels que les marchés nord-africains, où la digitalisation rapide de la collecte de données sinistres (déclaration via un

site internet, expertise à distance, bases de données mutualisées entre assureurs) crée pour la première fois les conditions de volume et de granularité nécessaires à l'entraînement de modèles d'apprentissage automatique, alors même que ces marchés restent caractérisés par des historiques de sinistres plus courts que ceux des marchés matures, ce qui renforce l'intérêt d'estimateurs robustes tels qu'IGNIS [3] face à des règles de calibration prudentielle de plus en plus alignées sur les standards internationaux de type Solvabilité II.

Notre démarche relève d'une revue de littérature synthétique et critique, en privilégiant les architectures neuronales appliquées explicitement aux copules, et les travaux de provisionnement non-vie qui mobilisent l'apprentissage automatique pour traiter la dépendance entre triangles. Pour chaque architecture, nous reportons les résultats empiriques tels que rapportés par leurs auteurs respectifs, sans extrapolation à des contextes ou des données non étudiés par les sources originales lorsque la littérature ne fournit pas de résultat chiffré directement transposable au provisionnement non-vie, nous le signalons explicitement plutôt que de substituer une estimation arbitraire.

Cette sélection ne prétend pas à l'exhaustivité, mais vise à couvrir la diversité des approches existantes, des plus génériques aux plus spécifiquement actuarielles.

Pour y répondre, nous organisons notre analyse comme suit. La section II rappelle les fondements des copules traditionnelles et leur application au provisionnement non-vie, et identifie leurs limites. La section III présente en détail les fondements mathématiques et les mécanismes d'apprentissage des principales architectures neuronales pour la modélisation des dépendances, qu'elles soient génériques ou spécifiques au provisionnement. La section IV propose une comparaison analytique structurée de ces approches selon plusieurs critères pertinents pour le provisionnement non-vie. La section V évalue de manière critique la portée et les limites de ces modèles. Enfin, la section VI conclut et ouvre des perspectives de recherche.

II. COPULES ET PROVISIONNEMENT NON-VIE : FONDEMENTS ET LIMITES

A. Rappel sur les copules

Une copule est une fonction de répartition multidimensionnelle définie sur l'hypercube unité $[0,1]^d$, dont les marges suivent une loi uniforme sur $[0,1]$. D'après le théorème de Sklar [7], toute fonction de répartition jointe F peut s'écrire comme la composition d'une copule C et des distributions marginales F_1 :

$$F(x_1, x_2, \dots, x_d) = C(F_1(x_1), F_2(x_2), \dots, F_d(x_d))$$

Cette décomposition est particulièrement utile en provisionnement, elle permet de modéliser séparément le comportement marginal de chaque triangle de développement (via, par exemple, un modèle de Mack ou un modèle linéaire généralisé) et la structure de dépendance entre les résidus ou les facteurs de développement de plusieurs lignes d'affaires [9]. Les familles paramétriques classiques utilisées à cette fin incluent les copules elliptiques (Gaussienne, Student) et les copules archimédiennes (Clayton, Gumbel, Frank, Joe).

B. Application aux réserves IBNyR et IBNeR

Plusieurs travaux ont appliqué les copules à la modélisation conjointe des composantes du calcul des réserves IBNR. Zaroudi et al. [1] proposent un modèle de dépendance fondé sur la copule de Clayton entre le délai inter-occurrences et le délai de déclaration des sinistres, estimé par maximum de vraisemblance et appliqué à un portefeuille automobile réel ; leur approche surpasse la méthode Chain-Ladder classique pour la prévision du nombre de sinistres futurs. Diao et Weng [2] utilisent une copule factorielle pour modéliser la dépendance spatiale entre sinistres de dommages aux biens consécutifs à une même tempête, ce qui permet de capturer la dépendance globale induite par le choc commun. Araichi [12] développe une approche de prévision du risque de réserve pour des pertes temporellement dépendantes, en modélisant explicitement la dépendance entre années de développement successives plutôt qu'en la supposant nulle comme dans le cadre Chain-Ladder classique.

Ces applications illustrent l'intérêt des copules pour le provisionnement, mais aussi leurs limites structurelles : le choix d'une famille paramétrique impose une forme de dépendance souvent trop rigide pour représenter fidèlement les renforcements de corrélation observés lors de chocs systémiques affectant simultanément plusieurs lignes d'affaires (par exemple une vague d'inflation touchant à la fois l'automobile et la responsabilité civile), ainsi que la dimension élevée d'un portefeuille multi-branches.

C. Familles paramétriques et dépendance de queue

Le choix d'une famille de copule conditionne directement le type de dépendance de queue que le modèle est capable de représenter. La copule de Clayton, définie par $C(u,v) = (u^{(-\theta)} + v^{(-\theta)} - 1)^{-1/\theta}$ pour $\theta > 0$, capture une dépendance asymétrique concentrée dans la queue inférieure : elle convient pour modéliser des événements où les sinistres faibles sur deux lignes d'affaires ont tendance à survenir conjointement. La copule de Gumbel, $C(u,v) = \exp(-[(-\ln u)^\theta + (-\ln v)^\theta]^{1/\theta})$ pour $\theta \geq 1$, modélise au contraire une dépendance concentrée dans la queue supérieure, pertinente pour représenter le risque que des sinistres extrêmes sur plusieurs branches surviennent simultanément lors d'un même choc systémique. La copule Gaussienne, en revanche, impose une dépendance symétrique et ne présente aucune dépendance de queue asymptotique ($\lambda = 0$), ce qui la rend structurellement inadaptée à la représentation des co-occurrences d'événements extrêmes pourtant centrales en gestion des risques d'assurance.

Cette rigidité constitue la principale motivation du recours à des modèles plus flexibles. En pratique, un assureur disposant de plusieurs lignes d'affaires doit souvent choisir a priori entre une copule capturant la dépendance de queue inférieure, une autre capturant la dépendance de queue supérieure, et une troisième sans dépendance de queue alors que la réalité des données peut combiner ces trois régimes selon la période ou le type de choc considéré. Les copules mixtes ou les vine copulas atténuent partiellement ce problème en combinant plusieurs familles bivariées, mais au prix d'une complexité croissante du nombre de paramètres à estimer, ce qui redevient problématique en présence de portefeuilles comportant de nombreuses lignes d'affaires et d'historiques de sinistres relativement courts une situation fréquente en provisionnement non-vie, où l'on dispose typiquement de quelques dizaines d'années de données par branche.

III. MODÈLES D'APPRENTISSAGE AUTOMATIQUE POUR LA DÉPENDANCE DES RÉSERVES

A. Taxonomie des approches neuronales

La littérature récente propose plusieurs architectures neuronales pour la modélisation des dépendances, que l'on peut classer en deux grandes catégories pour notre objet d'étude : (i) les architectures génériques de copules neuronales, applicables à tout problème de dépendance multivariée, et (ii) les architectures spécifiquement conçues pour le provisionnement non-vie, qui intègrent directement la structure du triangle de développement. Les sous-sections suivantes détaillent, pour chacune, la formulation mathématique sous-jacente et le mécanisme d'apprentissage qui la distingue de l'estimation paramétrique classique.

B. IGNIS : estimation neuronale robuste des paramètres archimédiens

Le réseau IGNIS [3] s'attaque à un problème précis : l'estimation par la méthode des moments du paramètre θ d'une copule archimédienne devient instable, voire biaisée, pour certaines lorsque la dépendance est faible ou que l'échantillon est de petite taille une situation représentative d'un assureur disposant d'un historique limité par ligne d'affaires. Plutôt que de maximiser une vraisemblance ou de résoudre l'équation des moments, IGNIS apprend une fonction de correspondance directe entre un vecteur de statistiques observables x et le paramètre θ , via un réseau de neurones à propagation avant dont la sortie est contrainte par la transformation :

$$\theta_{\text{sortie}} = \ln(1 + e^z) + 1$$

où z est la sortie linéaire de la dernière couche du réseau. Cette fonction softplus décalée garantit que θ_{sortie} reste toujours supérieur ou égal à 1, respectant ainsi le domaine de validité des familles archimédiennes considérées, quelle que soit la sortie brute du réseau une contrainte architecturale qui élimine par construction le risque de produire un paramètre invalide, contrairement à une estimation par moments qui peut produire des valeurs hors domaine en petit échantillon.

C. Copules neuronales génératives : DCC et architectures apparentées

Le Deep Copula Classifier (DCC), proposé par Aïch et al. [4], illustre une approche structurellement différente : il s'agit d'un modèle génératif qui sépare l'apprentissage des distributions marginales de celui de la

structure de dépendance, cette dernière étant modélisée par un réseau de neurones dont la sortie représente directement la densité de copule $c(u,v; \psi)$, paramétrée par les poids ψ du réseau plutôt que par un scalaire θ .

La classification bayésienne entre deux classes conditionnelles est alors obtenue en combinant les densités marginales estimées séparément avec cette densité de copule apprise, selon le rapport de vraisemblance classique de Bayes. Les auteurs établissent que, sous des conditions de régularité, le classifieur converge vers le classifieur bayésien optimal à un taux de convergence explicite, où n est la taille d'échantillon et d la dimension du problème un résultat théorique de nature similaire aux garanties de consistance disponibles pour les estimateurs paramétriques classiques, mais obtenu pour une classe de modèles non paramétriques.

D. Alternatives non paramétriques : GARCH-RBM et CokeNet

Loro [5] propose de remplacer entièrement la copule, dans le cadre GARCH-Copule usuel, par une machine de Boltzmann restreinte (RBM). Une RBM est un réseau stochastique non dirigé à deux couches une couche visible v représentant les rendements standardisés des actifs (ou, par transposition, des résidus de développement standardisés de plusieurs lignes d'affaires) et une couche cachée h dont la distribution jointe est définie par une fonction d'énergie bilinéaire :

$$E(v,h) = -a'v - b'h - v'Wh, \quad P(v,h) = \exp(-E(v,h)) / Z$$

où W est la matrice de poids reliant les deux couches, a et b les biais respectifs, et Z la fonction de partition normalisatrice. L'entraînement par divergence contrastive permet d'ajuster W , a et b pour que la distribution marginale des unités visibles reproduise la dépendance jointe empirique, sans qu'aucune forme fonctionnelle de copule ne soit imposée a priori. Loro [5] rapporte que cette architecture passe mieux à l'échelle qu'un GARCH-Copule classique pour un grand nombre d'actifs et capture davantage les événements de queue, en particulier lorsque l'entraînement est effectué sur des périodes ne contenant pas elles-mêmes d'événements extrêmes une propriété de généralisation directement pertinente pour le provisionnement, où les sinistres catastrophiques sont par construction sous-représentés dans l'historique d'entraînement.

$$\hat{\sigma}_k = \exp(\varphi_c(z_k)) / \sum_j \exp(\varphi_c(z_j))$$

où z_k désigne la représentation latente de la k -ième composante dans l'espace spectral et la somme au dénominateur porte sur l'ensemble des K composantes. Cette normalisation de type softmax garantit que les densités spectrales estimées restent comprises entre 0 et 1 et que leur somme totale égale 1, ce qui permet de les interpréter comme des probabilités. CokeNet a été développé et validé sur des données de nature spectrale plutôt qu'actuarielle ; son application directe à des triangles de développement nécessiterait une adaptation non encore documentée dans la littérature, ce que nous signalons explicitement plutôt que de présumer sa transférabilité.

E. Modèles à effets mixtes et marges arbitraires : COPNN

Simchoni et Rosset [13] introduisent COPNN (Copula-based Neural Networks), une architecture qui étend les modèles à effets mixtes couramment utilisés pour les données groupées ou longitudinales au-delà de l'hypothèse gaussienne usuelle. Dans un modèle à effets mixtes classique, la dépendance intra-groupe est modélisée par un effet aléatoire gaussien partagé.

COPNN remplace cette hypothèse par une copule gaussienne appliquée non pas directement aux observations, mais à leurs rangs transformés, ce qui permet de conserver la structure de dépendance flexible d'une copule tout en autorisant des marges arbitraires typiquement asymétriques et à queue lourde, comme c'est le cas pour les montants de sinistres apprises par un réseau profond plutôt que supposées gaussiennes. L'estimation procède par apprentissage par lots et descente de gradient stochastique, ce qui rend l'approche compatible avec de grands volumes de données individuelles de sinistres, à la différence des méthodes d'estimation par maximum de vraisemblance complète qui deviennent rapidement coûteuses lorsque le nombre de groupes augmente.

F. Chain-Ladder neuronal : enrichir les facteurs de développement

Wüthrich [8] propose une extension directe de la méthode Chain-Ladder de Mack, dans laquelle les facteurs de développement f_j , traditionnellement calculés comme un rapport de sommes agrégées sur le triangle, sont

remplacés par une fonction $f_j(x)$ dépendant des caractéristiques individuelles x de chaque sinistre (type de garantie, zone géographique, montant déclaré à l'ouverture), cette fonction étant elle-même paramétrée par un réseau de neurones à propagation avant entraîné séparément pour chaque période de développement j .

Le réseau est entraîné par minimisation de l'écart entre les paiements incrémentaux prédits et observés sur un ensemble d'apprentissage, avec validation croisée sur un ensemble de test constitué en isolant aléatoirement une partie des sinistres individuels. Appliqué à un portefeuille de sinistres individuels réparti sur plusieurs lignes d'affaires, Wüthrich [8] montre que l'introduction de covariables individuelles dans les facteurs de développement permet de capturer une hétérogénéité de portefeuille que la méthode Chain-Ladder agrégée, par construction, ne peut pas représenter, tout en conservant une cohérence structurelle avec le cadre actuariel établi.

G. DeepTriangle et son extension multi-lignes

Kuo [9] introduit DeepTriangle, une architecture récurrente à base de cellules GRU (gated recurrent unit) qui modélise conjointement, pour chaque ligne d'affaires et chaque compagnie, deux séries temporelles : les paiements incrémentaux cumulés et le montant des sinistres restant à payer (case reserves). Le modèle utilise des couches d'embedding pour représenter les variables catégorielles (ligne d'affaires, identifiant de compagnie) sous forme de vecteurs denses appris conjointement avec les poids récurrents, puis des couches entièrement connectées pour produire les prédictions finales. L'apprentissage est réalisé conjointement sur les triangles de plusieurs compagnies et lignes d'affaires simultanément plutôt que sur un seul triangle à la fois comme dans l'approche Chain-Ladder classique, ce qui permet au réseau de partager l'information statistique entre portefeuilles structurellement similaires.

Kuo améliore la précision prédictive par rapport à la méthode Chain-Ladder de Mack, au modèle bootstrap ODP (over-dispersed Poisson), à un ensemble de modèles d'apprentissage automatique automatisés (AutoML), ainsi qu'à une sélection de modèles bayésiens par chaînes de Markov Monte-Carlo, sur la majorité des lignes d'affaires étudiées, tout en notant explicitement que le modèle échoue à capturer la détérioration des ratios de sinistres sur certains portefeuilles atypiques (cas spécifiquement documenté pour la branche accidents du travail d'une compagnie de l'échantillon).

Cai et al. [10] étendent cette architecture avec l'Extended DeepTriangle (EDT), dont la contribution centrale consiste à modéliser explicitement la dépendance entre deux lignes d'affaires plutôt que de les traiter comme des sorties indépendantes d'un même réseau partagé. Pour ce faire, l'EDT introduit des connexions supplémentaires entre les représentations latentes des deux lignes à chaque pas de temps, capturant à la fois leur relation séquentielle et leur relation. Les auteurs rapportent que cette modélisation explicite de la dépendance inter-lignes réduit l'erreur de prévision des réserves par rapport à un traitement indépendant des deux lignes, et qu'elle permet une estimation plus précise du bénéfice de diversification.

H. Modèle hybride dense-récurrent avec attention

Schneider et Schwab [11] proposent une architecture hybride combinant des couches denses pour le traitement des caractéristiques statiques d'un sinistre (type de garantie, zone géographique) et un réseau récurrent de type LSTM (long short-term memory) augmenté d'un mécanisme d'attention pour le traitement des caractéristiques dynamiques (paiements successifs, statut du dossier).

Le mécanisme d'attention permet au réseau de pondérer différemment les périodes de développement passées selon leur pertinence pour la prédiction du paiement suivant, plutôt que de leur accorder un poids uniforme comme le ferait un modèle LSTM standard.

Les auteurs complètent cette évaluation par une analyse de robustesse fondée sur le bootstrap et par des valeurs de Shapley (SHAP) permettant de quantifier la contribution de chaque variable aux prédictions, ce qui constitue une tentative explicite de répondre à l'enjeu d'interprétabilité discuté en section V.

IV. COMPARAISON ANALYTIQUE DES APPROCHES

Cette section propose une comparaison structurée des approches présentées en section III, organisée selon des critères pertinents pour le choix d'une architecture en contexte de provisionnement non-vie : la forme de

dépendance représentable, le mécanisme d'apprentissage, le résultat empirique rapporté par les auteurs lorsqu'il est disponible et directement comparable, et le niveau de maturité pour une application actuarielle. Conformément à notre démarche méthodologique (section I.B), seuls les résultats explicitement rapportés dans les sources citées sont mentionnés ; lorsque la littérature ne fournit pas de résultat chiffré transposable, la case correspondante l'indique explicitement plutôt que de comporter une appréciation qualitative non vérifiable.

TABLE I. COMPARAISON ANALYTIQUE DES ARCHITECTURES NEURONALES POUR LA DÉPENDANCE EN PROVISIONNEMENT NON-VIE

Architecture	Forme de dépendance représentée	Mécanisme d'apprentissage	Résultat rapporté par les auteurs
IGNIS [3]	Paramètre scalaire θ d'une copule archimédienne existante	Régression supervisée sur données simulées, sortie contrainte	Réduction de l'erreur d'estimation par rapport à la méthode des moments.[3]
DCC [4]	Densité de copule non restreinte à une forme paramétrique	Apprentissage génératif, classification bayésienne	Convergence prouvée vers le classifieur bayésien optimal.
GARCH-RBM [5]	Dépendance jointe non paramétrique via énergie bilinéaire	Divergence contrastive	Meilleure capture des événements de queue qu'un GARCH-Copule, y compris hors période d'entraînement extrême. [5]
CokeNet [6]	Densité spectrale structurée par une fonction de copule	Normalisation softmax sur représentations latentes spectrales	Validé sur données spectrales ; transposition au provisionnement.
COPNN [13]	Copule gaussienne sur rangs, marges arbitraires apprises	Descente de gradient stochastique par minibatch	Permet des marges non gaussiennes adaptées aux montants de sinistres.
Chain-Ladder NN [8]	Facteurs de développement dépendant individuelles	Minimisation d'écart quadratique / déviance de Poisson par réseau dense	Capture une hétérogénéité de portefeuille inaccessible au Chain-Ladder agrégé.
DeepTriangle [9]	Dépendance implicite entre paiements et réserves restantes	Réseau récurrent GRU avec embeddings catégoriels	Améliore la précision par rapport au Chain-Ladder, à l'ODP.
Extended DeepTriangle [10]	Dépendance explicite inter-lignes	Connexions inter-séries ajoutées à l'architecture GRU	Réduit l'erreur de prévision et améliore l'estimation du bénéfice de diversification par rapport à un traitement indépendant des lignes. [10]

Cette comparaison fait apparaître trois constats analytiques. Premièrement, les résultats chiffrés disponibles ne sont pas directement comparables entre eux : ils proviennent de jeux de données, de lignes d'affaires et de métriques d'erreur différents.

Deuxièmement, les architectures qui rapportent une amélioration chiffrée et vérifiable par rapport au Chain-Ladder classique DeepTriangle [9], Extended DeepTriangle [10], le modèle hybride dense-LSTM-attention [11] partagent une caractéristique commune : elles sont construites comme des extensions directes d'une méthode actuarielle de référence plutôt que comme des architectures neuronales génériques important leur logique depuis d'autres domaines applicatifs.

Le Chain-Ladder neuronal de Wüthrich [8] partage cette logique de construction, mais son intérêt rapporté tient surtout à sa capacité structurelle à intégrer l'hétérogénéité individuelle plutôt qu'à un gain de précision chiffré directement comparable aux trois architectures précédentes. À l'inverse, les architectures les plus génériques ne disposent pas, à notre connaissance, de résultat empirique publié spécifiquement sur des données de provisionnement non-vie, ce qui limite la portée des conclusions que l'on peut en tirer pour notre objet d'étude et appelle à la prudence plutôt qu'à l'extrapolation.

Troisièmement, le seul résultat directement relatif à la dépendance inter-lignes d'affaires la réduction de l'erreur de prévision rapportée par Cai et al. pour l'Extended DeepTriangle [10] confirme qualitativement l'intuition théorique selon laquelle modéliser explicitement la dépendance entre branches apporte un gain par rapport à un traitement indépendant, mais cette étude ne fournit pas, dans les éléments accessibles pour cette revue, de quantification de l'effet sur le capital de risque réglementaire qui permettrait une transposition chiffrée directe au contexte prudentiel.

V. ÉVALUATION CRITIQUE

La principale force des approches neuronales réside dans leur capacité à approximer n'importe quelle fonction continue (théorème d'approximation universelle). Pour la dépendance entre réserves, cela signifie qu'un réseau suffisamment profond peut représenter des structures arbitrairement complexes, y compris des renforcements de corrélation en queue, des asymétries multiples entre branches et des interactions non linéaires de haut niveau, là où une copule paramétrique unique impose une forme rigide.

L'intégration de couches récurrentes ou de mécanismes d'attention, comme dans Schneider et Schwab [11], permet en outre aux modèles neuronaux de capturer des structures de dépendance variant dans le temps par exemple un renforcement progressif de la corrélation entre branches lors d'un cycle inflationniste là où les copules classiques supposent généralement la stationnarité de la dépendance sur toute la période d'observation.

Ces apports ont toutefois un coût. Premièrement, l'interprétabilité reste un défi majeur : alors que le paramètre θ d'une copule de Gumbel possède une signification statistique directe (l'intensité de la dépendance de queue supérieure), les poids d'un réseau neuronal ne se prêtent qu'à une interprétation indirecte, ce qui complique la justification du modèle que Schneider et Schwab [11] tentent explicitement d'atténuer en complétant leur modèle par une analyse de bootstrap et par des valeurs de Shapley quantifiant la contribution de chaque variable.

Deuxièmement, l'entraînement de copules neuronales peut être instable et sensible; certains travaux rapportent même que, dans plusieurs scénarios de test, les copules neuronales ne surpassent pas les méthodes classiques, ce qui invite à la prudence quant à une adoption non critique [14]. Troisièmement, le risque de surajustement sur des événements rares reste présent même lorsque les résultats globaux sont favorables.

Au-delà des résultats empiriques ponctuels discutés en section IV, les copules traditionnelles et les modèles neuronaux se distinguent par des propriétés structurelles intrinsèques, indépendantes. En matière de flexibilité structurelle, les copules classiques restent confinées à une famille paramétrique prédéfinie, tandis que les modèles neuronaux bénéficient du théorème d'approximation universelle une propriété mathématique générale et non un résultat empirique spécifique.

Une pratique raisonnable, cohérente avec la démarche de validation par bootstrap et SHAP suivie par Schneider et Schwab [11], consiste à calculer la provision selon la méthode Chain-Ladder ou un modèle GLM

classique, puis à évaluer empiriquement, sur un échantillon de validation propre au portefeuille étudié, si une architecture neuronale telle que l'Extended DeepTriangle [10] apporte un gain de précision ou de capture de la dépendance inter-lignes suffisant pour en justifier l'adoption.

VI. CONCLUSION

Cet article a examiné dans quelle mesure les modèles d'apprentissage automatique et les copules neuronales peuvent capturer des structures de dépendance entre réserves de sinistres non-vie que les copules traditionnelles ne peuvent reproduire. L'exposition détaillée des fondements mathématiques de IGNIS, DCC, GARCH-RBM, CokeNet et COPNN pour les copules neuronales génériques, et du Chain-Ladder neuronal, de DeepTriangle, de son extension multi-lignes et du modèle hybride dense-LSTM pour les approches spécifiques au provisionnement, montre que les architectures neuronales offrent un cadre structurellement plus flexible que les copules classiques.

Plus généralement, ces résultats s'inscrivent dans une tendance de fond de l'actuariat non-vie : le passage progressif de méthodes agrégées et paramétriques vers des approches granulaires et data-driven, capables d'exploiter l'information individuelle des sinistres et les relations entre lignes d'affaires. Cette évolution ne signe pas pour autant la disparition des méthodes classiques. Les copules paramétriques et la méthode Chain-Ladder conservent un rôle de référence, de validation et de communication avec les superviseurs prudentiels, précisément en raison de leur interprétabilité et de la maturité de leur cadre théorique.

La réponse à notre question initiale est donc positive, mais conditionnelle et nuancée : les modèles d'apprentissage automatique peuvent saisir des structures de dépendance que les copules traditionnelles ne peuvent reproduire, mais cette capacité théorique n'a été démontrée empiriquement, dans la littérature que nous avons examinée, que pour un sous-ensemble d'architectures spécifiquement adaptées au contexte du provisionnement, et sur des jeux de données spécifiques dont la généralisation à d'autres portefeuilles reste à établir.

Plusieurs pistes de recherche découlent directement des limites identifiées dans cet article. Premièrement, l'application des architectures génériques de copules neuronales à des données réelles de provisionnement non-vie d'affaires permettrait de combler le manque de résultats empiriques identifié en section IV et de déterminer si leur flexibilité théorique se traduit effectivement par un gain mesurable dans ce contexte spécifique. Deuxièmement, le développement de mesures d'interprétabilité spécifiquement adaptées au contexte prudentiel. Troisièmement, l'établissement d'un protocole de comparaison standardisé mêmes jeux de données, mêmes métriques d'erreur, mêmes lignes d'affaires entre les différentes architectures neuronales présentées dans cet article permettrait de dépasser les limites de comparabilité que nous avons soulignées en section IV. Enfin, l'extension de ces approches à la dépendance entre risques d'assurance et risques financiers.

RÉFÉRENCES

- [1] S. Zaroudi, M. R. Faridrohani, M. H. Behzadi, and H. Safari-Katesari, "Copula-based modeling for IBNR claim loss reserving," *Scientia Iranica*, vol. 31, no. 18, pp. 1596–1605, 2024.
- [2] X. Diao and C. Weng, "Copula-based regression model for replicated spatial data with application to property insurance," *ASTIN Bulletin*, presented at the IAA Colloquium on IBNR Claims Reserving, 2025.
- [3] A. Aich et al., "IGNIS: A neural network framework for robust parameter estimation in Archimedean copulas," *arXiv preprint*, arXiv:2505.22518, 2025.
- [4] A. Aich, A. B. Aich, and B. Wade, "Theoretical foundations of the Deep Copula Classifier: A generative approach to modeling dependent features," *arXiv preprint*, arXiv:2505.22997, 2025.
- [5] P. Loro, "On GARCH-Copula limitations: A novel approach using GARCH-restricted Boltzmann machine," M.S. thesis, Politecnico di Milano, Milan, Italy, 2024.
- [6] J. Tian, H. Xue, Y. Xue, and P. Fang, "Copula-nested spectral kernel network," in *Proc. 41st Int. Conf. Machine Learning (ICML)*, PMLR vol. 235, pp. 48280–48294, 2024.
- [7] R. B. Nelsen, *An Introduction to Copulas*, 2nd ed. New York, NY, USA: Springer, 2006.
- [8] M. V. Wüthrich, "Neural networks applied to chain-ladder reserving," *ASTIN Bulletin / AFIR Colloquium Paper*, International Actuarial Association, 2018.

- [9] K. Kuo, "DeepTriangle: A deep learning approach to loss reserving," *Risks*, vol. 7, no. 3, p. 97, 2019.
- [10] J. Cai, K. Kuo, et al., "Extended DeepTriangle: Modeling dependence between lines of business in loss reserving," *Variance*, 2025.
- [11] J. C. Schneider and B. Schwab, "Advancing loss reserving: A hybrid neural network approach for individual claim development prediction," *Journal of Risk and Insurance*, 2025.
- [12] S. Araichi, "Forecasting reserve risk for temporal dependent losses in insurance," *International Journal of Finance & Economics*, 2025.
- [13] G. Simchoni and S. Rosset, "Flexible copula-based mixed models in deep learning: A scalable approach to arbitrary marginals," in *Proc. 28th Int. Conf. Artificial Intelligence and Statistics (AISTATS)*, 2025.
- [14] J. Herbert, "Neural vs. classical copulas: Integrating financial dependence into Monte Carlo simulation," M.S. thesis, Umeå University, Umeå, Sweden, 2025.
- [15] A. Charpentier and M. Pigeon, "Macro vs. micro methods in non-life claims reserving (an econometric perspective)," *Risks*, vol. 4, no. 2, p. 12, 2016.