



Débats économiques et financiers

N°44

Modèles internes des banques pour le calcul du capital réglementaire (IRB) et intelligence artificielle

Henri Fraisse* et Christophe Hurlin†

* Autorité de Contrôle Prudentiel et de Résolution, henri.fraisse@acpr.banque-france.fr

† Université d'Orléans, christophe.hurlin@univ-orleans.fr

SECRETARIAT GENERAL DE L'AUTORITÉ DE CONTRÔLE PRUDENTIEL
ET DE RÉOLUTION

DIRECTION DE L'ÉTUDE ET DE L'ANALYSE DES RISQUES

MODÈLES INTERNES DES BANQUES POUR LE CALCUL DU CAPITAL
RÉGLEMENTAIRE (IRB) ET INTELLIGENCE ARTIFICIELLE³

Henri Fraise et Christophe Hurlin

Mars 2024

Les points de vue exprimés dans ces Débats Économiques et Financiers n'engagent que leurs auteurs et n'expriment pas nécessairement la position de l'Autorité de Contrôle Prudentiel et de Résolution. Ce document est disponible sur le site de l'Autorité de Contrôle Prudentiel et de Résolution : www.acpr.banque-france.fr

The opinions expressed in the Economic and Financial Discussion Notes do not necessarily reflect views of the Autorité de Contrôle Prudentiel et de Résolution. This document is available on www.acpr.banque-france.fr

³ Nous remercions les membres du Comité scientifique de l'ACPR pour leurs commentaires très utiles sur cette note.

Modèles internes des banques pour le calcul du capital réglementaire (IRB) et intelligence artificielle

Abstract: This note outlines the issues, risks and benefits of machine learning models for the design of internal credit risk assessment models used by banking institutions for the calculation of their own funds requirement ("Credit IRB Approach"). The use of ML models in IRB models is currently marginal. However, it could improve the predictive quality of models and in some cases lead to a reduction in capital requirements. However, ML models face a lack of interpretability that substitution or local approximation methods do not solve.

Keywords: Machine Learning; banking prudential regulation; internal models; regulatory capital

JEL Classification: G21, G29, C10, C38, C55

Modèles internes des banques pour le calcul du capital réglementaire (IRB) et intelligence artificielle

Résumé : Cette note expose les enjeux, les risques et les avantages des modèles d'apprentissage automatique (« Machine Learning ») pour la conception des modèles internes d'évaluation de risque de crédit utilisés par les établissements bancaires dans le cadre du calcul de leur exigence en fond propre (« Approche IRB Crédit »). L'utilisation des modèles ML dans le cadre des modèles IRB est pour l'instant marginale. Elle pourrait pourtant permettre d'améliorer la qualité prédictive des modèles et dans certains cas conduire à une réduction des exigences de fonds propres. Toutefois les modèles ML se heurtent à un déficit d'interprétabilité que les méthodes par substitution ou d'approximation locale ne résolvent pas.

Mots-clés : Machine Learning ; réglementation prudentielle bancaire ; modèles internes ; capital réglementaire

JEL Classification : G21, G29, C10, C38, C55

Modèles internes des banques pour le calcul du capital réglementaire (IRB) et intelligence artificielle

Henri Fraisse et Christophe Hurlin

Introduction

Cette note expose les enjeux, les risques et les avantages des modèles d'apprentissage automatique (« Machine Learning ») pour la conception des modèles internes d'évaluation de risque de crédit utilisés par les établissements bancaires dans le cadre du calcul de leur exigence en fond propre (« Approche IRB Crédit »). Elle s'inspire d'un document de travail publié sur le site de l'Institut Louis Bachelier¹.

1. Contexte réglementaire et discussions avec l'industrie : des méthodologies pour l'instant marginalement appliquées dans le cadre IRB mais potentiellement sources de variabilité dans le calcul des exigences en fonds propres

Dans ses dernières publications², l'Autorité Bancaire Européenne (ABE) a cherché à définir les attendus réglementaires quant à l'utilisation des modèles de Machine Learning (« ML », ci-après) dans le calcul des exigences en fonds propres des établissements bancaires. **L'ABE y définit les modèles ML comme des modèles complexes dont les paramètres sont estimés automatiquement à partir de données avec une intervention humaine limitée voire nulle.** Leur complexité réside dans les nombreux paramètres qui les caractérisent, paramètres estimés à l'aide d'une masse importante de données et capables de reproduire des phénomènes non linéaires. **Il s'agit donc de modèles de type boîte noire dont les prévisions sont difficiles, voire impossibles, à expliquer et à interpréter.**

Le cadre réglementaire actuel (CRR, CRD) ne s'oppose pas à l'utilisation de modèles issus d'algorithmes de ML. Pour autant, leur utilisation pourrait aller à l'encontre du but visé par le cadre réglementaire à venir (CRR3, CRD 6), à savoir celui d'une variabilité moins grande des exigences en fonds propres résultant de l'utilisation des modèles internes.

¹ Hurlin, C. et C. Pérignon (2023), « [Machine Learning et modèles IRB : Avantages, Risques et Préconisations](#) », *Collection Opinions et Débats*, Institut Louis Bachelier.

² EBA/REP/2023/28 "Machine Learning for IRB Models : follow-up report from the consultation on the discussion paper on machine learning for IRB models", Août 2023 et EBA/DP/2021/04 "EBA Discussion Paper on Machine Learning for IRB Models", Novembre 2021.

Si rien n'empêche a priori l'utilisation de modèles issus d'algorithmes de ML pour l'estimation des paramètres de risque de crédit, force est de constater que ces modèles sont pour l'instant peu utilisés en pratique par les banques dans le domaine réglementaire. Cette faible utilisation est d'autant plus surprenante que plusieurs rapports montrent que le ML est par ailleurs largement utilisé dans l'industrie bancaire dans de nombreux domaines, y compris dans la gestion du risque de crédit hors périmètre réglementaire. Ainsi, parallèlement aux travaux de l'ABE, l'Institut de la Finance Internationale (IIF) a mené deux enquêtes sur l'utilisation du ML dans le secteur du risque de crédit en 2019 et 2022 auprès de 60 banques (États-Unis 10, Canada 4, zone euro 14, reste de l'Europe 7, Asie et Japon 9) et 43 banques. (États-Unis 4, Canada 2, zone euro 7, reste de l'Europe 7, Asie 11), respectivement.³ Dans ces enquêtes, les établissements rapportent une large utilisation des modèles ML principalement dans le cadre de la construction de modèles d'octroi de crédit, mais à l'inverse une faible utilisation pour le calcul du capital réglementaire. Ces observations rejoignent celles faites récemment par l'ABE pour les banques européennes (EBA/REP/2023/28).

2. Bénéfices et coûts de l'utilisation des modèles ML : une meilleure capacité prédictive mais une interprétabilité limitée

Par rapport aux méthodes classiques, les méthodes de ML ont la capacité de sélectionner de façon flexible la forme fonctionnelle du lien entre la variable cible (typiquement une variable binaire associée au défaut) et les caractéristiques disponibles dans la base de données (typiquement les variables socio-démographiques d'un ménage et le fonctionnement de son compte bancaire). En outre, elles peuvent être appliquées en présence d'un grand nombre de prédicteurs. Elles sélectionnent de façon autonome les variables qui entrent dans la spécification du modèle. Enfin et surtout, elles peuvent créer de nouveaux prédicteurs en combinant et/ou en transformant les prédicteurs initiaux. Ces propriétés rendent les modèles de ML particulièrement efficaces pour détecter de façon autonome des non-linéarités et des interactions entre les prédicteurs. **La littérature académique montre clairement que certaines méthodes de ML, notamment les méthodes d'ensemble, prévoient le risque significativement mieux que les méthodes économétriques actuellement en place dans les établissements bancaires en approche avancée.** Toutefois, il est montré que les gains de performance prédictive permis par le ML ont tendance à plafonner avec la complexité des modèles.

Au-delà d'un gain en performance prédictive, l'utilisation du ML peut également produire des gains de productivité. Ainsi, dans le cadre d'une approche classique de la modélisation IRB, la construction d'un modèle de probabilité de défaut (« PD » ci-après) repose généralement sur une chaîne de prétraitements des données et des variables comme par exemple le traitement des valeurs manquantes, la discrétisation des variables continues, le regroupement de modalités des variables discrètes, etc. Or certains modèles de ML peuvent être utilisés de façon efficace sans appliquer ces prétraitements aux données et aux variables.

³ Voir IIF (2019), Machine Learning in credit Risk, Summary Report, August 2019 et IIF (2022). Survey report on Machine Learning uses in credit risk and AML applications. Le SSM a récemment lancé une enquête dans le cadre d'un sous-groupe de travail du réseau sur les modèles internes (« Network on Internal Models »). Compte tenu des réponses, le sous-groupe a en charge de déterminer si la rédaction de lignes directrices réglementaires serait nécessaire.

Le problème principal de l'utilisation des modèles ML est que ceux-ci peuvent être très complexes, ce qui rend difficile, voire impossible, l'interprétation de leurs prédictions et la compréhension des facteurs qui ont contribué à ces prédictions. Pour pallier cette difficulté, on peut mettre en œuvre des méthodes d'interprétabilité dites ex-post, i.e., qui sont appliquées une fois que le modèle a été entraîné. Ces méthodes d'interprétabilité peuvent être globales ou locales. Un exemple de méthode globale consiste à construire un modèle de substitution reliant les prévisions du modèle boîte noire aux données d'entrée, et qui soit nativement interprétable. Les méthodes locales fournissent une explication à une décision prise par le modèle boîte noire au niveau individuel, par exemple au niveau d'un emprunteur.

Mais cette démarche qui consiste à utiliser un modèle de ML de type boîte noire comme modèle de différenciation des risques, puis à mettre en œuvre ex-post une méthode d'interprétabilité / explicabilité locale ou globale est aujourd'hui très discutée en raison des limites inhérentes à ces méthodes. En premier lieu, les méthodes d'interprétabilité ex-post peuvent fournir des explications qui ne sont pas parfaitement fidèles au fonctionnement du modèle. Ensuite, les explications fournies par différentes méthodes d'interprétabilité pour un même modèle, sont parfois incohérentes les unes par rapport aux autres. Cette démarche en deux temps se fonde sur la croyance, largement admise dans l'industrie jusqu'alors, selon laquelle il existerait un arbitrage entre performance prédictive et interprétabilité. Dès lors que les modèles de ML les plus performants pour prédire le risque de crédit sont des boîtes noires, il serait alors justifié de mettre en œuvre des techniques d'interprétabilité ex-post même si elles ne fournissent qu'une compréhension limitée ou imparfaite des mécanismes internes du modèle.

Or, **des travaux académiques récents remettent en cause l'opposition entre performance prédictive et interprétabilité.** Plusieurs études théoriques et appliquées dans le contexte du risque de crédit montrent en effet qu'**il existe des modèles de ML nativement interprétables tout aussi performants que les meilleurs modèles de type boîte noire.** Ainsi se développe un courant de recherche qui s'intéresse à l'utilisation de méthodes de ML nativement interprétables dans toutes les applications à haut risque de l'IA, et notamment dans le domaine du crédit. Plusieurs études montrent, que ces modèles de ML interprétables peuvent tout à fait fournir des estimations des paramètres de risque aussi précises que les modèles de type boîte noire habituellement considérés comme les plus performants (voir par exemple Dumitrescu et al. (2022) ; Flachaire et al. (2023)). Ces nouvelles approches pourraient permettre de lever les freins au développement du ML liés à la question de l'interprétabilité.

3. Enjeux réglementaires de l'utilisation de modèles ML pour la conception des modèles IRB : des données non structurées et une absence d'interprétabilité posant des problèmes de conformité

Le superviseur, les services de validation interne et les organes décisionnels de la banque doivent pouvoir s'assurer que les paramètres utilisés pour le calcul des exigences de fonds propres reflètent fidèlement le niveau de risque pris par l'institution.⁴ Par conséquent, **les modèles IRB doivent être facilement interprétables et compréhensibles à la fois par la direction de la banque, afin qu'elle puisse prendre des décisions stratégiques en matière**

⁴ Voir Articles 174et 185 de la CRR.

d'allocation de portefeuille de façon éclairée, et par le superviseur en charge de l'application des réglementations prudentielles. Or, les modèles de ML les plus performants pour la gestion du risque de crédit sont précisément non interprétables et sont typiquement assimilés à des boîtes noires, ce qui limite par conséquent leur usage dans le contexte IRB (voir par exemple Fraisse et Laporte (2022) pour une étude des effets de l'adoption de l'IA sur le calcul des exigences en fond propre bancaire).

Le ML permet d'exploiter de nouveaux types de données.⁵ Le caractère de nouveauté doit s'entendre ici par référence aux données traditionnelles d'un modèle de score portant typiquement sur la nature du crédit, les caractéristiques de l'emprunteur (âge, revenus, situation matrimoniale, etc.) ou son historique bancaire. Ces nouvelles données sont d'origines très variées, mais elles proviennent généralement de l'open banking mis en œuvre dans le cadre de la Directive européenne sur les systèmes de paiement (DSP2), de la digitalisation de la relation clientèle, des réseaux sociaux, etc. **Toutefois, l'utilisation de ce type de données dans le contexte réglementé des modèles IRB impose de garantir l'exactitude, l'exhaustivité et l'adéquation des données utilisées. Ces contraintes sont souvent incompatibles avec la collecte, la transformation et l'utilisation des nouvelles sources de données.** Par exemple, la CRR impose aux établissements de crédit d'estimer les PD par classe de risque à partir des moyennes de long terme des taux de défaut à un an et d'utiliser une période d'observation historique d'au moins cinq ans. Or, pour de nombreuses données alternatives, de tels historiques ne sont tout simplement pas disponibles.

Une plus grande précision dans l'estimation des paramètres de risque n'implique pas nécessairement une diminution des RWA et des fonds propres réglementaires. Premièrement, rien n'indique que les gains prédictifs associés au ML soient dus à une surestimation du risque de défaut par les approches paramétriques traditionnelles. Deuxièmement, les éventuelles économies de fonds propres supposent une meilleure différenciation en risque, c'est-à-dire une amélioration de l'aptitude du modèle à regrouper des contreparties présentant des risques similaires. **Il existe encore peu d'études académiques visant à mesurer quel pourrait être l'impact d'une substitution du ML aux modélisations économétriques usuelles utilisées en approche avancée, sur les niveaux de RWA et de fonds propres réglementaires. Mais ces études aboutissent globalement à des conclusions mitigées et très variables.** Suivant les portefeuilles, les tests de validation et les modèles de ML considérés, on observe ainsi des augmentations ou des réductions de fonds propres réglementaires. Cette diversité illustre le risque d'une variabilité accrue des niveaux de capital réglementaire entre les banques IRB si l'adoption du ML dans ce contexte ne s'accompagnait pas de recommandations techniques précises. **Pour l'instant, les rares études prospectives concluent que lorsque les méthodes ML conduisent à des gains en RWA, ces gains sont davantage dus à une meilleure différenciation en risque qu'à une plus grande précision des paramètres de risque.**

⁵ Pour certains, cela serait même la seule manière d'augmenter réellement les performances des modèles d'octroi de crédit (Oskarsdottir et al., 2019).

Conclusion :

L'utilisation des modèles ML dans le cadre des modèles IRB est pour l'instant marginale. Elle pourrait pourtant permettre d'améliorer la qualité prédictive des modèles et dans certains cas conduire à une réduction des exigences de fonds propres. Toutefois les modèles ML se heurtent à un déficit d'interprétabilité que les méthodes par substitution ou d'approximation locale ne résolvent pas.

Une façon de sortir de cette situation consisterait à promouvoir l'utilisation de modèles de ML nativement interprétables. Utilisés dans le contexte de la différenciation des risques, des modèles de ML interprétables peuvent tout à fait fournir des estimations des paramètres de risque aussi précises que les modèles de type boîte noire, habituellement considérés comme plus performants. Même si ces nouvelles approches permettent de lever les freins au développement du ML liés à la question de l'interprétabilité, n'en demeurent pas moins les défis de la gouvernance et de la formation des personnels.

REFERENCES

Autorité Bancaire Européenne (2023), “Machine Learning for IRB Models: follow-up report from the consultation on the discussion paper on machine learning for IRB models”, *EBA/REP/2023/28*, Août 2023.

Autorité Bancaire Européenne (2021), “EBA Discussion Paper on Machine Learning for IRB Models”, *EBA/DP/2021/04*, Novembre 2021.

Dumitrescu, E., S. Hué, C. Hurlin et S. Tokpavi (2022), “Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects”, *European Journal of Operational Research*, 297(3):1178–1192.

Flachaire, E., S. Hué, S. Laurent et G. Hacheme, (2023), “Interpretable Machine Learning Using Partial Linear Models”, *Oxford Bulletin of Economics and Statistics*, <https://doi.org/10.1111/obes.12592>.

Fraisse H. et M. Laporte (2022), “Return on investment on artificial intelligence: The case of bank capital requirement”, *Journal of Banking & Finance*, Volume 138.

Hurlin, C. et C. Pérignon (2023), “Machine Learning et modèles IRB : Avantages, Risques et Préconisations”, *Collection Opinions et Débats*, Institut Louis Bachelier.

Institut de la Finance Internationale (IIF) (2019), “Machine Learning in Credit Risk, Summary Report”, Août 2019.

IIF (2022), “Survey report on Machine Learning uses in credit risk and AML applications”, Décembre 2022.

Oskarsdottir, M., C. Bravo, C. Sarraute, J. Vanthienen and B. Baesens (2019), “The value of big data for credit scoring: Enhancing financial inclusion using mobile phone data and social network analytics”, *Applied Soft Computing*, 74:26–39.

Débats Économiques et Financiers

1. M. Dietsch et H. Fraisse, « De combien le capital réglementaire diffère-t-il du capital économique : le cas des prêts aux entreprises par les grands groupes en France », Février 2013.
2. O. de Bandt, N. Dumontaux, V. Martin et D. Médée, « Mise en œuvre de stress tests sur les crédits aux entreprises », Mars 2013.
3. D. Nouy, « Les risques du Shadow banking en Europe : le point de vue du superviseur bancaire », Avril 2013.
4. L. Frey, S. Tavoraro, S. Viol, « Analyse du risque de contrepartie de la réassurance pour les assureurs français », Avril 2013.
5. D. Nouy, « La réglementation et la supervision bancaire dans les 10 prochaines années et leurs effets inattendus », Mai 2013.
6. O. de Bandt, J-C. Héam, C. Labonne, S. Tavoraro, « Mesurer le risque systémique suite à la crise financière », Juin 2013.
7. B. Camara, L. Lepetit, A. Tarazi, « Capital Initial, Changements par Composantes du Capital Réglementaire et Risques Bancaires », Juin 2013.
8. H. Fraisse, M.Lé, D. Thesmar, « Les effets réels des exigences en fonds propres », Aout 2013.
9. M. Lé, « Mise en place d'un mécanisme de garantie des dépôts et risque bancaire : le rôle du levier financier », Décembre 2013.
10. S. Tavoraro, F. Visnovsky, « Une analyse de la mesure SRISK comme outil de supervision », Janvier 2014.
11. O. de Bandt, B. Camara, P. Pessarossi, M. Rose, « Regulatory changes and the cost of equity: evidence from French banks », Mars 2014.
12. O. de Bandt, B. Camara, P. Pessarossi, M. Rose, « Does the capital structure affect banks' profitability? Pre- and post-financial crisis evidence from significant banks in France », Mars 2014.
13. M. Dietsch, C. Welter-Nicol, « Est-ce que les plafonds de LTV et de DSTI rendent les banques plus résilientes ? », Août 2014.
14. M. Chaffai, M. Dietsch, « Modelling and measuring business risk and the resiliency of retail banks », Décembre 2014.
15. G. Hauton, J.-C. Héam, « Comment mesurer l'interconnectivité entre banques, assureurs et conglomérats ? », Décembre 2014.
16. P. Pessarossi, F. Vinas, « L'offre de crédit de long-terme des banques après un choc de liquidité: le cas de 2007-2009 », Février 2015.
17. F. Borel-Mathurin, P.-E. Darpeix, Q. Guibert, S. Loisel, « Principaux déterminants de la stratégie de revalorisation dans le secteur de l'assurance-vie en France », Juillet 2015.
18. H. Fraisse, J. Hombert et M. Lé, « Les impacts d'une mégafusion sur la distribution du crédit », Octobre 2015.

19. B. Camara, F-D. Castellani, H. Fraise, L. Frey, J-C. Héam, C. Labonne et V. Martin, « MERCURE : a macroprudential stress testing model developed at the ACPR », Octobre 2015.
20. C. Labonne et C. Welter-Nicol, « Cheap Credit, Unaffordable Houses », Décembre 2015.
21. F. Vinas, « The real effects of universal banking on firm's investment: Micro-evidence from 2004-2009 », Avril 2016.
22. I. Argimon, M. Dietsch, et A. Estrada, « Prudential filters, portfolio composition and capital ratios in European banks », Août 2016.
23. M. Dietsch, K. Düllmann, H. Fraise, P. Koziol et C. Ott, « Support for the SME Supporting Factor - Multi-country empirical evidence on systematic risk factor for SME loans », Octobre 2016.
24. O. de Bandt, B. Camara, A. Maitre et P. Pessarossi, « Optimal capital, regulatory requirements and bank performance in times of crisis: Evidence from France », Octobre 2016.
25. Eugenio Avisoa, « European banks' technical efficiency and performance: do business models matter? The case of European co-operatives banks », Décembre 2016.
26. B. Camara, P. Pessarossi et T. Philippon, « Back-testing European stress tests », Janvier 2017.
27. E. Chrétien et V. Lyonnet, « Traditional and Shadow Banks during the Crisis », Mai 2017.
28. M. Birn, M. Dietsch, D. Durant, « How to reach all Basel requirements at the same time? », Juin 2017.
29. H.Fraise, « Restructuration de la dette des ménages : les effets d'un moratoire sur le redépôt en surendettement », Octobre 2017.
30. J. Hombert et V. Lyonnet, « Intergenerational Risk Sharing in Life Insurance: Evidence from France », Octobre 2017.
31. P. Pessarossi, J-L. Thevenon et L. Weill, « Does high profitability hamper stability for European banks? », Décembre 2017.
32. F. Borel-Mathurin, S. Loisel et J. Segers, « Reevaluation of the capital charge in insurance after a large shock: empirical and theoretical views », Décembre 2017.
33. A. Violon, D. Durant, O. Toader, « The Impact of the Identification of GSIBs on their Business Model », Mars 2018.
34. E. Kintzler, M. Lé et K. Parra Ramirez, « Importance et Intégration des Centres Financiers Extraterritoriaux dans l'Architecture Financière Internationale » Janvier 2019.
35. O. de Bandt, S. Lecarpentier et C. Pouvelle, « Les déterminants de la liquidité bancaire : une perspective française sur les interactions entre les exigences du marché et les exigences réglementaires », Septembre 2020.
36. O. de Bandt et G. Overton, « Les déterminants des défaillances en assurance : comparaison entre les secteurs de l'assurance à partir d'une nouvelle base de données internationale », Septembre 2020.

37. E. Monnet, A. Riva et S. Ungaro, « Les effets réels des ruées bancaires. L'exemple de la Grande Dépression en France (1930-1931) », Mai 2021.
38. L. Clerc, C. Lubochinsky, C. Pouvelle et A. Tarazi, « Les interactions entre les normes de capital et de liquidité bancaires dans le cadre de Bâle 3 : Une revue de la littérature », Mai 2022.
39. C. Pouvelle, « Une analyse de la résilience des conglomérats financiers : Une perspective sur la bancassurance en France », Décembre 2022.
40. T. Nicolas, « Pouvoir de marché des banques et fixation des taux d'intérêt : de l'importance de prendre en compte les données bancaires sur base consolidée », Janvier 2023
41. T. Nicolas, S. Ungaro et E. Vansteenbergh, « Prêts Garantis par l'État, Prise de Risque Bancaire et Effet d'Aubaine sur le Capital Réglementaire », Juin 2022.
42. P. Beaumont, H. Tang et E. Vansteenbergh, « Effets collatéraux : le rôle des FinTechs dans le financement des petites et moyennes entreprises », Mars 2024.
43. E. Vansteenbergh, « Insurance Supervision under Climate Change: A Pioneers Detection Method », Mars 2024.

Economic and Financial Discussion Notes

1. M. Dietsch and H. Fraisse, "How different is the regulatory capital from the economic capital: the case of business loans portfolios held by major banking groups in France", February 2013.
2. O. de Bandt, N. Dumontaux, V. Martin and D. Médée, "Stress-testing banks' corporate credit portfolio", March 2013.
3. D. Nouy, "The risks of the Shadow banking system in Europe: the perspective of the banking supervisor", April 2013.
4. L. Frey, S. Tavoraro, S. Viol, "Counterparty risk from re-insurance for the French insurance companies", April 2013.
5. D. Nouy, "Banking regulation and supervision in the next 10 years and their unintended consequences", May 2013.
6. O. de Bandt, J-C. Héam, C. Labonne and S. Tavoraro, "Measuring Systemic Risk in a Post-Crisis World", Juin 2013.
7. B. Camara, L. Lepetit, and A. Tarazi, "Ex ante capital position, changes in the different components of regulatory capital and bank risk", Juin 2013.
8. H. Fraisse, M.Lé, D. Thesmar, "The Real Effects of Bank Capital Requirements", August 2013.
9. M. Lé, "Deposit Insurance Adoption and Bank Risk-Taking: the Role of Leverage", December 2013.
10. S. Tavoraro and F. Visnovsky, "What is the information content of the SRISK measure as a supervisory tool?", January 2014.
11. Olivier de Bandt, Boubacar Camara, Pierre Pessarossi, Martin Rose, "Regulatory changes and the cost of equity:evidence from French banks", March 2014.
12. Olivier de Bandt, Boubacar Camara, Pierre Pessarossi, Martin Rose, "Does the capital structure affect banks' profitability? Pre- and post-financial crisis evidence from significant banks in France", March 2014.
13. Michel Dietsch and Cécile Welter-Nicol, "Do LTV and DSTI caps make banks more resilient?", August 2014.
14. M. Chaffai and M. Dietsch, "Modelling and measuring business risk and the resiliency of retail banks", December 2014.
15. G. Hauton, J-C. Héam, "How to Measure Interconnectedness between Banks, Insurers and Financial Conglomerates?", December 2014.
16. P. Pessarossi, F. Vinas, "Banks' supply of long term credit after a liquidity shock: Evidence from 2007-2009", February 2015.
17. F. Borel-Mathurin, P.-E. Darpeix, Q. Guibert, S. Loisel, "Main determinants of profit sharing policy in the French life insurance industry", July 2015.
18. H. Fraisse, J. Hombert and M. Lé, "The competitive effects of a bank megamerger on access to credit", October 2015.

19. B. Camara, F-D. Castellani, H. Fraisse, L. Frey, J-C. Héam, C. Labonne and V. Martin, "MERCURE : a macroprudential stress testing model developed at the ACPR", October 2015.
20. C. Labonne and C. Welter-Nicol, "Cheap Credit, Unaffordable Houses", December 2015.
21. F. Vinas, "The real effects of universal banking on firm's investment: Micro-evidence from 2004-2009", April 2016.
22. I. Argimon, M. Dietsch, and A. Estrada, "Prudential filters, portfolio composition and capital ratios in European banks", August 2016.
23. M. Dietsch, K. Düllmann, H. Fraisse, P. Koziol and C. Ott, "Support for the SME Supporting Factor - Multi-country empirical evidence on systematic risk factor for SME loans", October 2016.
24. O. de Bandt, B. Camara, A. Maitre and P. Pessarossi, "Optimal capital, regulatory requirements and bank performance in times of crisis: Evidence from France", October 2016.
25. Eugenio Avisoa "European banks' technical efficiency and performance: do business models matter? The case of European co-operatives banks", December 2016.
26. B. Camara, P. Pessarossi and T. Philippon, "Back-testing European stress tests", January 2017.
27. E. Chrétien and V. Lyonnet, "Traditional and Shadow Banks during the Crisis", May 2017.
28. M. Birn, M. Dietsch, D. Durant "How to reach all Basel requirements at the same time?", June 2017.
29. H. Fraisse, "Household Debt Restructuring: The Re-default Effects of Debt Suspensions", October 2017.
30. J. Hombert and V. Lyonnet, "Intergenerational Risk Sharing in Life Insurance: Evidence from France", October 2017.
31. P. Pessarossi, J-L. Thevenon and L. Weill, "Does high profitability hamper stability for European banks?", December 2017.
32. F. Borel-Mathurin, S. Loisel and J. Segers, "Reevaluation of the capital charge in insurance after a large shock: empirical and theoretical views" December 2017.
33. A. Violon, D. Durant, O. Toader "The Impact of the Identification of GSIBs on their Business Model", March 2018.
34. E. Kintzler, M. Lé and K. Parra Ramirez, "Importance and integration of offshore financial centers into the global financial system", January 2019.
35. O. de Bandt, S. Lecarpentier and C. Pouvelle, "Determinants of Banks' Liquidity: a French Perspective on Interactions between Market and Regulatory Requirements", September 2020.
36. O. de Bandt, and G. Overton, "Why do insurers fail? A comparison of life and non-life insolvencies using a new international database", September 2020.
37. E. Monnet, A. Riva and S. Ungaro, "The real effects of bank runs. Evidence from the French Great Depression", May 2021.

38. L. Clerc, C. Lubochinsky, C. Pouvelle and A. Tarazi, "Interactions of bank capital and liquidity standards within the Basel 3 framework: A literature review", May 2022.
39. C. Pouvelle, "An Analysis of Financial Conglomerate Resilience: A Perspective on bancassurance in France", December 2022.
40. T. Nicolas, "Bank Market Power and Interest Rate Setting: Why Consolidated Banking Data Matter", January 2023.
41. Nicolas, S. Ungaro and E. Vansteenberghe, "Public-Guaranteed Loans, Bank Risk-Taking and Regulatory Capital Windfall", June 2023.
42. . P. Beaumont, H. Tang and E. Vansteenberghe, "Collateral Effects: The Role of FinTech in Small Business Lending", March 2024.
43. E. Vansteenberghe, "Insurance Supervision under Climate Change: A Pioneers Detection Method", March 2024.