

L'intelligence artificielle appliquée à la rhéologie et à la mise en œuvre réactive des polymères

Résumé Les données et l'intelligence artificielle ont fait irruption dans de nombreux domaines de la science et de l'ingénierie, et la science et l'ingénierie des polymères n'ont pas été l'exception. Cet article a pour objectif de réconcilier les méthodologies basées sur la connaissance, c'est-à-dire les modèles issus de la physique, qui ont eu du succès tout au long du siècle dernier, avec cette toute nouvelle méthodologie basée sur l'emploi de données. C'est dans ce cadre, qualifié d'hybride, que les données viendront enrichir les modèles existants, et ces derniers permettront de transformer le paradigme des données massives dans celui des données « smart », plus économe et adapté à l'ingénierie. Il est fait appel ici à la science des données pour prouver la possibilité d'établir des modèles rhéologiques et des procédés complexes, telle l'extrusion réactive, dont les modélisations basées sur la physique font défaut ou ne sont pas suffisamment générales et/ou précises, grâce aux données expérimentales.

Mots-clés Polymères, IA, apprentissage machine, données, rhéologie, procédés.

Abstract Artificial intelligence applied to rheology and implementation of polymers

Data and artificial intelligence irrupted in numerous domains of science and technology, and polymers science and engineering are not an exception. This paper aims at conciliating methodologies based on the existing knowledge, that is physics-based models, that supported the amazing last century progresses and accomplishments, with a really new paradigm based on the smart data collection, assimilation and curation. This new framework that constitutes a hybrid paradigm enables data-based models' enrichment, and at the same time models allow data becoming smarter and more adapted to common and new engineering practices. This paper illustrates how data-science is applied for deriving data-drive models of polymer rheology and of complex polymer processing, like reactive extrusion, that as here proved, and can be successfully addressed by assimilating data concerning material and process parameters and their associated product properties and performances.

Keywords Polymers, AI, machine learning, data, rheology, processing.

L'intelligence artificielle entre en scène

Initialement, l'industrie a adopté les outils de simulation, basés sur la physique, pour représenter les matériaux, procédés, structures et systèmes. Cependant, les moyens de calcul plutôt limités dans les petites et moyennes entreprises ne permettaient pas de simuler les problèmes industriels aussi vite que les ingénieurs l'auraient souhaité. Malgré cela, ces outils de calcul ont transformé leur métier en offrant des moyens de conception optimisés, devenus incontournables dans la presque totalité des industries à la fin du XX^e siècle.

C'est au début du XXI^e siècle que les données font irruption dans la science et dans l'ingénierie, au moment où la simulation abandonne les bureaux d'études, la R & D, pour descendre dans l'atelier, sortir dans la rue (systèmes autonomes) et au-delà, accompagner les produits de l'ingénierie tout au long de leur vie. Dans un tel cadre, la simulation du XX^e siècle n'avait pas la capacité de fournir des réponses dans les temps requis, en temps réel, sauf en utilisant des moyens de calcul disproportionnés...

Au XXI^e siècle, nous n'achetons plus de moteurs d'avion mais des heures de vol, de trains d'atterrissage mais un nombre d'atterrissages garanti, de perceuses mais plutôt des trous de bonne qualité... Nous devenons plus attentifs aux performances qu'à la gestion des produits eux-mêmes.

Pendant des années, les données collectées massivement ont pu être classifiées, décortiquées, analysées... à l'aide des techniques d'intelligence artificielle (IA). Ces données massives ont pu fournir des clés d'interprétation, avertir d'un événement fortuit imminent, rendant possible une

maintenance prédictive, une surveillance et une prise de décision en temps réel.

Cependant, dans le cadre de l'ingénierie et de l'industrie, les modèles basés sur l'IA ont été rapidement confrontés à deux difficultés récurrentes majeures : la nécessité d'une quantité faramineuse de données pour aboutir à des prédictions précises et fiables (comme illustré dans la *figure 1*), sachant que donnée est synonyme de coût (coûts d'acquisition et de traitement), ainsi que la difficulté d'expliquer les prédictions que « l'intelligence artificielle » offre, et avec cette dernière, la difficulté de certifier les produits de l'ingénierie. En effet, le monde de l'ingénierie semble bien différent de ces autres domaines où les données foisonnent ; les modèles, quand ils existent, restent d'une validité douteuse et les conséquences des prises de décision restent loin des exigences imposées aux desseins en ingénierie [1-3]. Malgré d'énormes succès dans de nombreux domaines – l'ingénierie et l'industrie manufacturière entre autres –, la question reste posée. Mais les grandes difficultés ont parfois une solution simple : et si nous combinons modèles et données ? Comme disent les Français souvent : « Avoir le beurre et l'argent du beurre » ! Et oui, entre « toute donnée » et « toute physique », c'est le paradigme hybride qui devrait s'imposer.

L'IA est aujourd'hui considérée comme un ensemble de techniques permettant : la visualisation de données multidimensionnelles ; la classification (supervisée) ou le groupement (non supervisé) des données sur le principe que les données de la même classe ou groupe expriment des comportements similaires ; la modélisation des relations reliant entrées et sorties, c'est-à-dire actions et réactions ; et enfin,

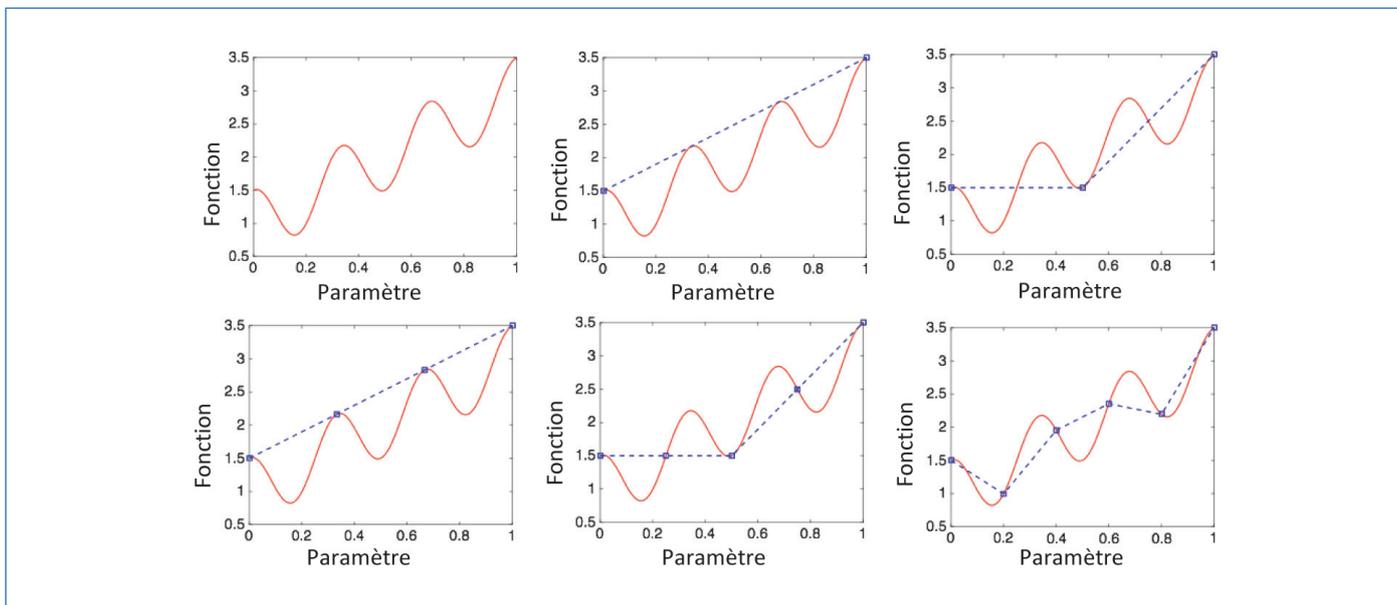


Figure 1 - Cette figure met en évidence l'énorme différence entre une fonction analytique (en haut à gauche) et la même fonction (en rouge) décrite par des données et des interpolations linéaires entre elles (en bleu). Il en ressort l'énorme économie en compacité de la première par rapport à la deuxième. Ainsi, les descriptions basées exclusivement sur les données semblent compromises et, dans la mesure du possible, à éviter, sauf quand des données massives ou une dose de connaissance sont à la porte.

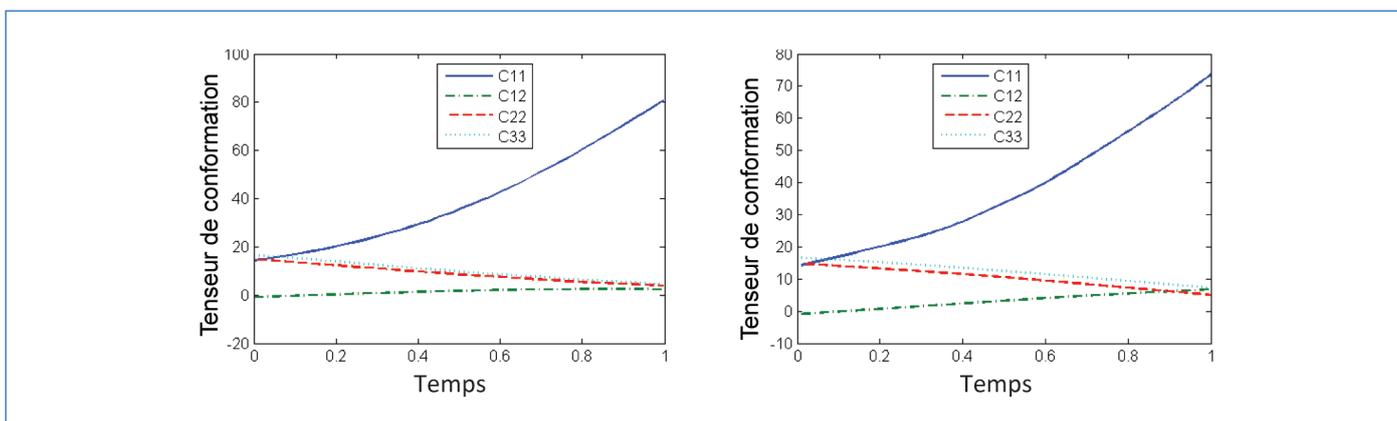


Figure 2 - Comparaison de simulations directes (gauche) et prédiction du réseau de neurones (droite) en ce qui concerne la conformation moléculaire (orientation et extension des chaînes) dans un écoulement caractérisé par le gradient de vitesses $\nabla V_{11} = 1,77$, $\nabla V_{12} = 0,822$.

l'extraction de connaissances qui reste un enjeu majeur tout comme l'explication/certification.

Des applications pour les matériaux

IA et modèles rhéologiques des polymères

Les polymères et les fluides viscoélastiques peuvent être décrits à différentes échelles [4-7]. À l'échelle moléculaire, les interactions atomiques sont prises en compte et rendent les descriptions précises, mais compromettent leur utilisation dans les échelles propres des procédés. C'est là où l'IA peut permettre un passage d'échelle conjuguant simplicité et efficacité, comme nous allons le voir par la suite.

Pour y parvenir, une population de chaînes est simulée à l'échelle moléculaire avec les techniques de simulation décrites dans [8]. Le calcul est extrêmement coûteux, mais permet de décrire le matériau à l'échelle microscopique, c'est-à-dire la relation existant entre l'effort appliqué et la vitesse de déformation induite, ainsi que l'état intime du matériau décrit par une série de variables dites « de conformation », décrivant notamment l'orientation et l'élongation des

chaînes moléculaires. Malgré la finesse de ce type de description, il ne peut pas être employé dans le cadre des simulations des procédés industriels.

Nous avons proposé d'utiliser des techniques d'apprentissage machine (IA) où des régressions non linéaires sont employées, en particulier un réseau de neurones entraîné pour appréhender à partir des simulations microscopiques le taux de changement de la conformation moléculaire d'une population de molécules en fonction de la conformation elle-même, ainsi que des propriétés locales de l'écoulement, ces dernières données par le tenseur gradient de vitesses.

La *figure 2* compare les évolutions de la conformation à l'issue de la simulation microscopique d'une population de molécules avec la prédiction obtenue pour le réseau de neurones entraîné pour un écoulement mixte (combinant cisaillement et élongation).

La pertinence des outils d'IA a d'ores et déjà apporté des avancées dans plusieurs domaines à l'industrie des polymères. Nous avons choisi d'étudier deux systèmes réactifs qui sont des systèmes modèles, suffisamment complexes pour justifier l'utilisation de méthodes d'intelligence artificielle.

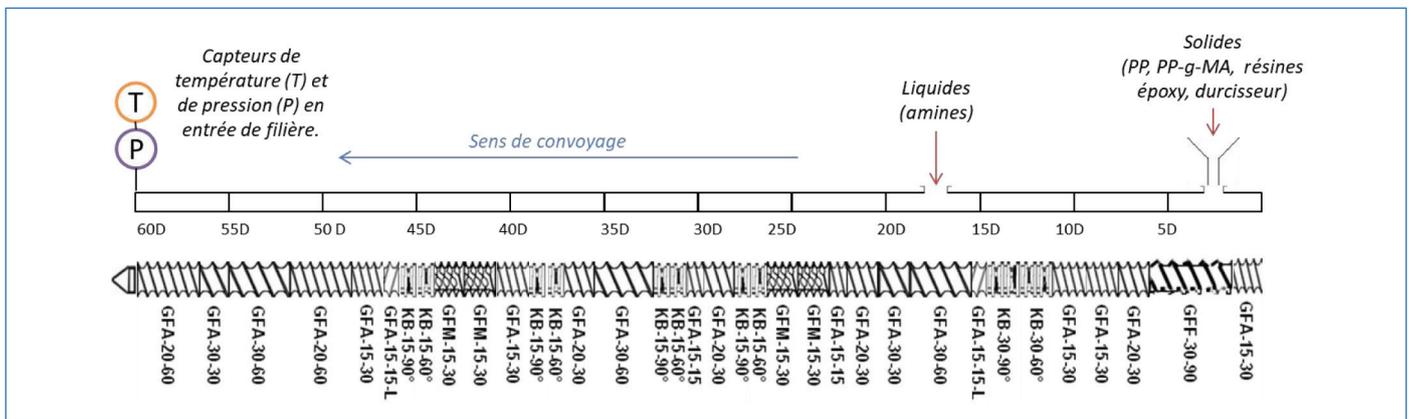


Figure 3 - Schéma du profil de vis utilisé dans l'étude.

Renforcement du polypropylène par une phase thermodurcissable

L'objectif est la dispersion d'une phase thermodurcissable (TS) dans une matrice polypropylène (PP) par polymérisation *in situ* de la phase thermodurcissable à partir d'une résine époxy et d'une amine comme durcisseur.

Ces études ont été réalisées dans le cadre d'un projet avec le groupe Total sur la base d'un brevet déposé par Hutchinson [9]. Ce brevet décrit le procédé de préparation d'un thermoplastique renforcé en dispersant un agent de renforcement réactif non miscible et qui constitue après réaction *in situ* la phase thermodurcissable. Le résultat de cette opération est un mélange polymère composé d'une phase homogène renforcée par une phase dispersée finement (< 5 mm), conduisant à une amélioration des propriétés mécaniques du polymère thermoplastique.

Plusieurs polypropylènes ont été testés pour étudier les variations de viscosité. La phase thermodurcissable est basée sur des dérivés DGEBA (bisphénol A diglycidyl éther) qui sont des composants à l'origine de résines époxy. Deux différentes résines ont été testées ainsi que trois agents durcisseurs pour former trois couples résine/durcisseur différents. Ces systèmes ont été choisis afin d'étudier l'influence de leur structure, leur masse molaire et leur nature chimique sur la génération *in situ* de la phase thermodurcissable au sein de la matrice PP. Un polypropylène greffé avec environ 1 % en masse d'anhydride maléique, PP-g-MA (PO1020 d'Exxon), a été utilisé comme agent de compatibilisation entre la matrice PP et la phase thermodurcissable. Les produits utilisés pour ces mélanges sont décrits en détail dans [10].

Les formulations ont été réalisées en une seule étape avec une extrudeuse à double vis corotative (Leistritz ZSE18, L/D = 60, D = 18 mm), dont le profil est décrit dans la figure 3.

Deux profils de température différents ont été utilisés (200 et 230 °C), ainsi que plusieurs vitesses de rotation (N = 300, 600, 450, 800 tr/min) et débits de vis (débits de sortie : 3, 5, 6, 10 kg/h) pour étudier l'influence du procédé sur les propriétés des matériaux.

Le module de Young a été déterminé par des tests de traction à une vitesse de 1 mm/min et la contrainte seuil, l'allongement à la rupture et la contrainte à la rupture ont été mesurés avec une vitesse de traction de 50 mm/min. La résistance aux chocs à température ambiante a été déterminée par test Charpy sur des échantillons entaillés.

Pour relier la formulation et les paramètres procédés aux propriétés finales, différentes méthodes d'apprentissage machine (régressions non linéaires) seront appliquées. Les

paramètres de traitement sont regroupés dans la variable dite d'entrée x :

$$x = \begin{pmatrix} \text{Vitesse de rotation [rpm]} \\ \text{Débit de sortie [kg/h]} \\ \text{Température [°C]} \\ \text{TS phase dispersée [\%]} \\ \text{rapport (PP - g - MA/TS)} \\ \text{TS stœchiométrie} \end{pmatrix}$$

tandis que les propriétés des matériaux traités sont regroupées dans la variable à cinq entrées y , comprenant le module de Young, la contrainte seuil, la contrainte à la rupture, la déformation à la rupture et la résistance au choc :

$$y = \begin{pmatrix} E \text{ [MPa]} \\ \sigma_y \text{ [MPa]} \\ \sigma_b \text{ [MPa]} \\ \epsilon_b \text{ [-]} \\ Re_{amb} \text{ [kJ/m}^2\text{]} \end{pmatrix}$$

Parmi les données expérimentales utilisées, une partie n'a pas servi à l'établissement des régressions (« training ») mais a été réservée afin de quantifier leur performance.

Différentes régressions ont été utilisées [10-13] : les réseaux de neurones (NN), le Code2Vect (C2V), la « sparse PGD » (sPGD), le « support vector machine » (SVM), les arbres de décision (D.TREE) et la méthode DMD incrémentale (iDMD) permettent de prédire des propriétés pour des variables d'entre données, avec une précision dans la prédiction de l'ordre de la variabilité des données (voir tableau I).

Tableau I - Erreurs relatives pour les différentes techniques de régression.

Erreur relative (%)	E	σ_{seuil}	σ_{rupture}	$\epsilon_{\text{rupture}}$	Re_{amb}
NN	23	24	35	100	43
C2V	15	16	22	105	37
SPGD	18	19	30	107	34
SVM	14,5	17	30	107	37
D. TREE	17	17	30	94	40
iDMD	16	17	28	96	34

L'établissement d'un modèle d'un procédé complexe pourrait servir à des fins de contrôle de procédé en temps réel, mais aussi, comme c'est le cas dans cette étude, à comprendre les principales tendances de chaque quantité d'intérêt par rapport à chaque paramètre du procédé ou de la formulation,

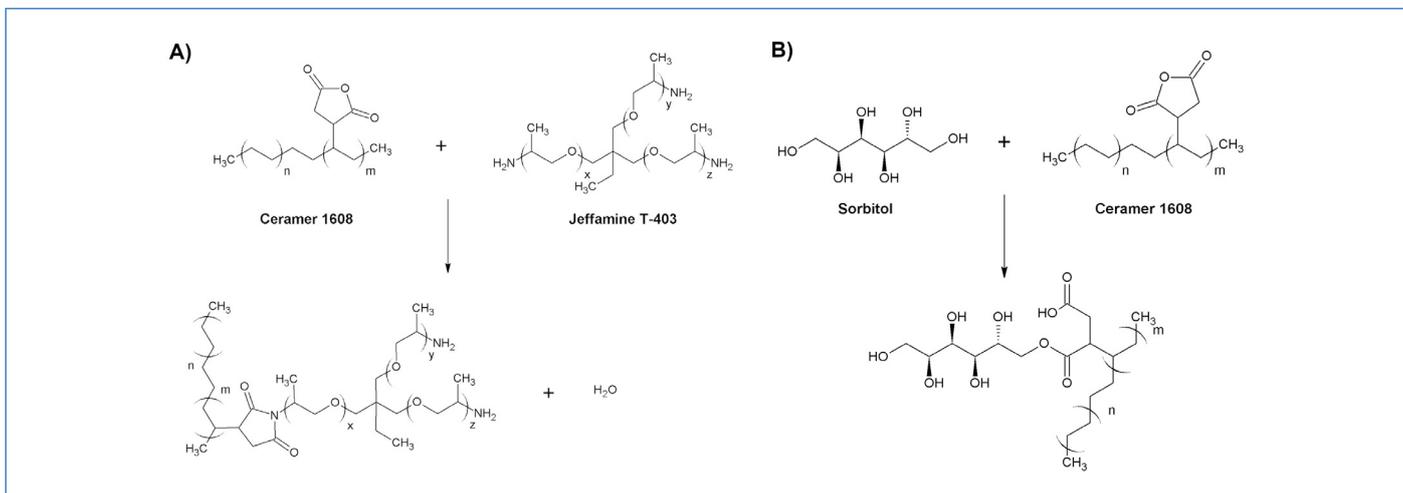


Figure 4 - A) Réaction possible entre Ceramer 1608 et la Jeffamine T-403. B) Réaction entre Ceramer 1608 et le sorbitol.

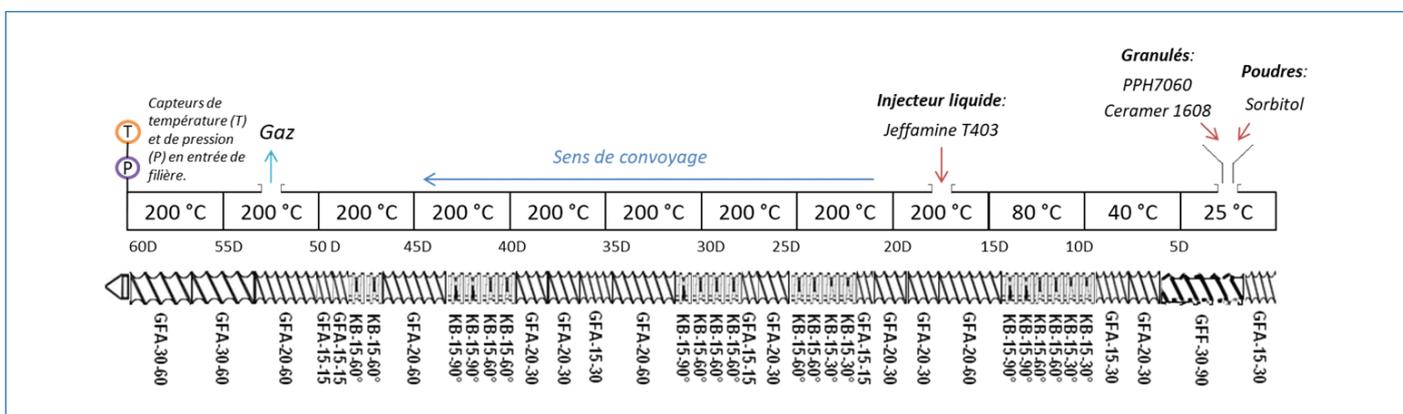


Figure 5 - Schéma de la configuration de l'extrudeuse utilisée dans l'étude.

ce qui permettrait d'optimiser le procédé et le matériau final.

Une limitation importante, inhérente aux stratégies de « machine learning », est le fait que, très probablement, d'autres facteurs non considérés ici comme paramètres d'entrée pourraient être déterminants pour exprimer les sorties sélectionnées. C'est un point intéressant qui est actuellement en développement.

Synthèse d'une phase dispersée polyéthylène réticulé

Cette étude consiste à disperser dans le PP une phase polymère polyéthylène (PE) réticulé résultant de la réaction *in situ* d'un oligomère de polyéthylène greffé PE-g-MA avec une triamine ou un sorbitol. Les réactions ont été réalisées par un procédé d'extrusion réactive en une seule étape.

Nous avons utilisé ici un système précédemment développé dans notre laboratoire dans le cadre d'une thèse de doctorat [14]. Il s'agit de la réaction entre un oligomère de PE linéaire greffé avec des dérivés d'anhydride maléique (Ceramer 1608, Baker Hughes) et un oligomère de polyétheramine trifonctionnel (Jeffamine T-403, Huntsman). La réaction donne lieu à un réseau réticulé dont la valeur du module de conservation à l'équilibre est similaire aux caoutchoucs synthétiques ($G_e \approx 5 \times 10^5$ Pa). L'objectif est donc de réaliser cette réaction *in situ* dans une matrice de PP par extrusion réactive. Le PP utilisé ici est le PPH7060 de Total. Un système similaire a également été étudié en remplaçant la triamine par un sorbitol (D(-)-sorbitol, VWR Chemicals).

Les mécanismes réactionnels, présentés dans la figure 4, sont parfaitement connus dans la chimie des polymères. Le rapport en masse Ceramer 1608/Jeffamine T-403 a été fixé à 75/25, et le rapport Ceramer 1608/sorbitol à 85/15.

Les systèmes choisis sont assez complexes par leur chimie et la solubilité des réactifs, et il est donc difficile de transcrire les conditions réelles dans une simulation comme Ludovic® en termes par exemple de formation de réseaux (conversion de la réaction) en fonction du temps et de la température. La figure 5 montre le schéma des conditions opératoires utilisées.

Les formulations du système Ceramer/Jeffamine dispersé dans le PP ont été réalisées en opérant avec des vitesses de rotation de la vis de 200 à 1 000 t/mn et un débit de sortie de 3 à 20 kg/h. Deux formulations ont été testées pour ce système avec $\phi = 15$ wt% et $\phi = 30$ wt% de phase dispersée. Concernant le système Ceramer/sorbitol, il a été dispersé à $\phi = 20$ wt% dans le PP pour des vitesses de rotation de vis à 300 et 800 tr/min et débits de sortie de 5 et 10 kg/h.

Une modélisation de ce procédé a été réalisée à l'aide du logiciel Ludovic®, un modèle d'extrusion bi-vis développé par Vergnes *et coll.* [15]. Le profil de la vis, les dimensions de l'extrudeuse et de la filière et la température du fourreau ont été définis pour correspondre à nos expériences. Concernant les propriétés de ces fluides, du fait que le logiciel ne peut pas prendre en compte la phase dispersée, et encore moins les réactions chimiques qui s'y produisent, nous avons supposé que le comportement rhéologique du mélange est

uniquement déterminé par la matrice. Par conséquent, la simulation a été réalisée en considérant une seule phase PP. Malgré les nombreuses simplifications et hypothèses impliquées dans cette simulation, les résultats obtenus numériquement pour le système Ceramer/Jeffamine sont assez proches des valeurs expérimentales et pourraient suffire dans la plupart des cas. L'hypothèse faite en considérant une phase unique et homogène semble donc ne pas altérer la précision du modèle dans ce cas.

Cependant, pour le système Ceramer/sorbitol, la simulation semble moins adaptée aux expériences et surévalue les résultats. Il apparaît donc que la phase dispersée a finalement une influence significative sur le comportement du matériau. En effet, cette réaction est plus lente et comme les viscosités des réactifs sont nettement inférieures à la viscosité du polypropylène (rapport de viscosité de 7×10^{-4} entre le Ceramer et le PP), on peut supposer que le système réactif a un effet lubrifiant avant de créer une phase dispersée de viscosité suffisamment élevée pour être dispersée dans la matrice PP. Ce phénomène a été décrit par Cassagnau *et coll.* pour différents systèmes réactifs [16]. Par conséquent, nous ne pouvons plus approximer la viscosité du matériau à la viscosité de la matrice, mais devons considérer une viscosité apparente plus faible (effet lubrifiant), du moins en début du mélange.

Finalement, il semblerait que les simulations des modélisations classiques ne soient pas parfaitement adaptées pour décrire les mélanges de polymères, en particulier les mélanges à faible rapport de viscosité.

C'est à ce niveau que la science des données et l'apprentissage machine deviennent pertinents à utiliser pour améliorer les simulations existantes. Dans cette partie, l'objectif est de tester la méthode d'hybridation données-modèle (« hybrid-twin » [17-18]) et de la comparer à des régressions basées exclusivement sur les données telles que celles utilisées dans la partie précédente.

Les données proviennent de deux sources différentes : d'une part du logiciel de simulation Ludovic®, qui seront appelées données de simulation, et d'autre part de mesures expérimentales, appelées données expérimentales. Les deux ensembles de données ont les quatre mêmes sorties à prévoir, à savoir couple, pression, puissance du moteur et température de sortie. Les données de simulation ont deux entrées, le débit et la vitesse de rotation, tandis que les données expérimentales comprennent un paramètre d'entrée supplémentaire, la phase dispersée. Ce dernier paramètre n'a pas été pris en compte dans le modèle en raison des limites du modèle Ludovic®.

Dans ce qui suit, chacun des quatre résultats aura une vérité de base et un modèle de premier ordre. La vérité de base pour le couple, la pression et la puissance du moteur sont les mesures expérimentales, alors que le modèle de premier ordre correspond aux données de simulation. Concernant la température, un défaut a été décelé au niveau de la mesure expérimentale. En effet, le thermocouple de l'extrudeuse étant trop proche de la paroi de la filière, il ne mesure pas la température réelle au cœur du matériau. Il s'est alors avéré que le logiciel Ludovic® donne des valeurs de températures plus proches de la réalité (information vérifiée au moyen d'un thermocouple manuel). Pour cette raison, pour la température, on considère que la vérité de base correspond aux données de simulation alors que les mesures expérimentales définissent le modèle du premier ordre.

L'ensemble de données expérimentales contient 47 échantillons (ou mesures). Les mêmes 47 échantillons ont été reproduits à partir de la simulation (Ludovic®). L'objectif principal est de disposer d'un modèle de régression capable d'inférer les résultats pour n'importe quel point de l'espace paramétrique. À cette fin, l'ensemble de données initial est divisé en 38 points pour construire la régression (« training ») et 9 points pour vérifier l'exactitude de la prédiction (test).

La procédure consiste à soustraire les valeurs correspondant au modèle du premier ordre à celles correspondant à la vérité de base. Une régression (sPGD ou Code2Vect) est appliquée à cette déviation. Ce faisant, on s'attend à ce que certaines corrélations soient déjà expliquées par le modèle du premier ordre facilitant la construction de la régression et ses performances. Ainsi, le modèle de la déviation devrait être plus facile à déterminer que le modèle basé exclusivement sur les données.

Le *tableau II* indique les erreurs relatives pour les techniques C2V et sPGD. Comme on peut le constater, la technique C2V pour le couple et la technique sPGD pour la puissance du moteur sont plus performantes que l'approche basée exclusivement sur les données. Il est également important de souligner que la température de sortie est plus difficilement prédite. Ce problème peut s'expliquer par le fait que les températures mesurées et calculées ne correspondent pas, l'une correspondant au centre du matériau et l'autre à la paroi de la filière.

Tableau II - Erreurs relatives pour la modélisation hybride (« hybrid-twin »).

Erreur HT (%)	Puissance moteur	Pression filière	Couple	Température filière
sPGD train	9,8	7,4	11,3	0,9
C2V train	2,4	1,6	1,3	0,2
sPGD test	13,0	6,8	12,6	0,8
C2V test	12,0	10,5	7,4	6,2

Gagner en efficacité

Nous avons illustré dans cet article l'intérêt des techniques de modélisation basées sur les données dans deux contextes différents et à forte valeur ajoutée : quand des modélisations existent mais sont très chères en temps de calcul (et du point de vue des ressources de calcul associées), et quand la complexité des matériaux et procédés rend les prédictions basées sur les modèles très incertaines. Dans les deux cas, l'option de construire et exploiter des modèles à partir de données permet de gagner de l'efficacité sans sacrifier la précision.

[1] F. Chinesta, R. Keunings, A. Leygue, *The proper generalized decomposition for advanced numerical simulations. A primer*, SpringerBriefs, Springer, 2014.

[2] F. Chinesta, A. Huerta, G. Rozza, K. Willcox, Model order reduction, in *Encyclopedia of Computational Mechanics*, 2nd ed., E. Stein, R. de Borst, T. Hughes (eds), John Wiley & Sons, 2015.

[3] F. Chinesta *et al.*, Parametric PGD based computational vademecum for efficient design, optimization and control, *Arch. Comput. Methods Eng.*, 2013, 20, p. 31-59.

[4] C. Binetruy, F. Chinesta, R. Keunings, *Flows in polymers, reinforced polymers and composites. A multiscale approach*, SpringerBriefs, Springer, 2015.

[5] R.B. Bird, C.F. Curtiss, R.C. Armstrong, O. Hassager, *Dynamics of Polymeric Liquids, Vol. 2: Kinetic Theory*, John Wiley & Sons, 1987.

[6] F. Chinesta, E. Abisset, *A journey around the different scales involved in the description of matter and complex systems*, SpringerBrief, Springer, 2017.

- [7] M. Doi, S.F. Edwards, *The Theory of Polymer Dynamics*, Oxford Sciences Publications, **1986**.
- [8] A. Ammar, F. Chinesta, Direct numerical simulation of flexible molecules and data-driven molecular conformation, *Comptes Rendus Mécanique*, **2019**, 347, p. 743-753.
- [9] N. Garois, P. Sonntag, G. Martin, M. Vatan, J. Drouvroy, Procédé de préparation d'une composition thermoplastique renforcée et réactive, cette composition et son utilisation, Brevet FR2963624-B1, **2014**.
- [10] R. Ibañez *et al.*, On the data-driven modeling of reactive extrusion, *Fluids*, **2020**, 5, p. 1-23.
- [11] R. Ibañez *et al.*, A multi-dimensional data-driven sparse identification technique: the sparse proper generalized decomposition, *Complexity*, **2018**, ID 5608286.
- [12] C. Argerich, R. Ibañez, A. Barasinski, F. Chinesta. Code2Vect: an efficient heterogenous data classifier and nonlinear regression technique, *Comptes Rendus Mécanique*, **2019**, 347, p. 754-761.
- [13] A. Reille *et al.*, Incremental dynamic mode decomposition: a reduced-model learner operating at the low-data limit, *Comptes Rendus Mécanique*, **2019**, 347, p. 780-792.
- [14] M. Robert, Rheology and morphology of polyolefin/functional oligomer blends: application to the formulation of polymer materials, thèse de doctorat, **2019**.
- [15] B. Vergnes, G. Della Valle, L. Delamare, A global computer software for polymer flows in corotating twin screw extruders, *Polym. Eng. Sci.*, **1998**, 38, p. 1781-92.
- [16] P. Cassagnau, F. Fenouillot, Rheological study of mixing in molten polymers: 2-mixing of reactive systems, *Polymer*, **2004**, 45, p. 8031-40.

- [17] F. Chinesta, E. Cueto, E. Abisset-Chavanne, J.L. Duval, F. El Khaldi, Virtual, digital and hybrid twins. A new paradigm in data-based engineering and engineered data, *Arch. Comput. Methods Eng.*, **2020**, 27, p. 105-134.
- [18] D. Gonzalez, F. Chinesta, E. Cueto, Learning corrections for hyperelastic models from data, *Frontiers in Materials - Computational Materials Science*, **2019**, 6, 14.

Fanny CASTÉRAN, doctorante, **Karim DELAGE**, ingénieur d'études, **Philippe CASSAGNAU**, professeur, Université Claude Bernard Lyon 1, Ingénierie des Matériaux Polymères, CNRS, UMR 5223, Villeurbanne.

Francisco CHINESTA*, professeur, PIMM Lab/Chaire ESI Groupe, Arts et Métiers Institute of Technology, Paris.

Elias CUETO, professeur, Aragon Institute of Engineering Research, Universidad de Zaragoza, Zaragoza (Espagne).

Amine AMMAR, professeur, LAMPA, Arts et Métiers Institute of Technology, Angers.

Nicolas GAROIS, directeur R & D Polymères thermoplastiques, Hutchinson, Centre de Recherche, Chalette-sur-Loing.

*francisco.chinesta@ensam.eu

CHIMIE ET...

Déjà 22 titres dans cette collection...
Des livres à mettre en toutes les mains !



Commandez en ligne sur laboutique.edpsciences.fr

edp sciences