

Apprentissage Automatique pour Estimation du Courant des Convertisseurs DC/DC Fonctionnant en Modes de Conduction Continue et Discontinue

Gerardo BECERRA*, Fredy RUIZ†, Diego PATINO‡, Minh T. PHAM§, Xuefang LIN-SHI¶.

* ESTIA Recherche, 90 Allée Fauste d'Elhuyar, 64210, Bidart, France. gerardo.becerra@estia.fr

† Politecnico di Milano, Piazza Leonardo da Vinci, 32, Milano, 20133, Italie. fredy.ruiz@polimi.it

‡ Pontificia Universidad Javeriana, Cra 7 No. 40 - 62, Bogotá, Colombie. patino-d@javeriana.edu.co

§ INSA Lyon, Université Claude Bernard Lyon 1, École Centrale de Lyon, CNRS, Ampère, UMR5005, 69621 Villeurbanne, France. minh-tu.pham@insa-lyon.fr

¶ INSA Lyon, Université Claude Bernard Lyon 1, École Centrale de Lyon, CNRS, Ampère, UMR5005, 69621 Villeurbanne, France. xuefang.shi@insa-lyon.fr

RESUME - Le problème de l'estimation de courant dans les convertisseurs de puissance commutés fonctionnant en modes de conduction continue et discontinue est examiné dans cet article. Une méthode est présentée pour la synthèse d'un estimateur sans connaissance exacte du modèle mathématique du système. Contrairement aux approches trouvées dans la littérature, qui utilisent des modèles hybrides ou modèles moyennés pour représenter la dynamique du convertisseur de puissance dans chaque mode de fonctionnement, la structure de la méthode proposée est plus simple. Cette dernière repose sur un algorithme utilisant le calcul parallèle et des techniques de réduction de dimensionnalité. La méthode est validée dans le cas d'un convertisseur SEPIC (single ended primary inductor converter). Les résultats de simulation et expérimentaux sont présentés et discutés. La méthode proposée montre de meilleurs résultats d'estimation par rapport à d'autres approches bien connues basées sur des modèles et des données.

ABSTRACT - The problem of current estimation in switched power converters operating in continuous and discontinuous conduction modes is considered. A method is presented for direct design of an estimator without exact knowledge of the mathematical model of the system. The structure of the proposed method is simpler than other approaches found in the literature, which use hybrid or averaged models to represent the dynamics of the power converter in each operating mode. An algorithm implementation using parallel computation and dimensionality reduction techniques for improving the execution performance is described. The method is demonstrated in the case of the SEPIC (single ended primary inductor converter), where simulation and experimental results are discussed. The proposed method shows better estimation results with respect to other well known modelbased and data-based approaches.

MOTS-CLES - Observateur, apprentissage automatique, convertisseurs de puissance DC-DC, modes de fonctionnement continu et discontinu

1. Introduction

Pour des convertisseurs de puissance DC/DC à commutation, la connaissance précise des courants et des tensions est une exigence importante pour atteindre des performances élevées dans les tâches de contrôle et de surveillance. En particulier, la mesure du courant est essentielle dans différentes stratégies de régulation basées sur la conception de boucles de contrôle séparées pour le courant et la tension. Dans ce contexte, la précision de la mesure du courant est cruciale, et des circuits de détection spéciaux sont nécessaires [1], [2]. Le principal inconvénient de cette approche est la nécessité d'inclure des circuits complexes pour capturer, filtrer et adapter le signal de courant à des fins de mesure. Cela augmente généralement le coût et crée des contraintes supplémentaires lors de la conception du circuit.

Une approche alternative consiste à estimer les courants à l'aide d'observateurs. La plupart des observateurs décrits dans la littérature pour l'estimation du courant sont basés sur des modèles moyens pour les convertisseurs de puissance fonctionnant en mode de conduction continue (CCM). Cependant, dans certaines conditions, ces convertisseurs peuvent fonctionner en mode de conduction discontinue (DCM). Cela peut être causé par des conditions externes telles que des changements soudains de charge ou peut être imposé par le concepteur pour des raisons d'efficacité. En DCM, la dynamique sous-jacente devient complexe, rendant inutile l'application d'observateurs basés sur le modèle moyen.

Il n'y a pas beaucoup de travaux dans la littérature concernant le problème de l'observation de variables d'état dans les convertisseurs de puissance fonctionnant en CCM et DCM. Les travaux antérieurs reposent sur l'existence d'un modèle pour le convertisseur de puissance et nécessitent l'utilisation d'un estimateur pour obtenir le mode de fonctionnement à chaque instant [3], [4], [5]. Dans ce papier, nous abordons le problème de l'estimation du courant dans les convertisseurs fonctionnant en CCM et DCM. Une méthode d'apprentissage automatique est mise en œuvre pour fournir directement des estimations en temps discret du courant moyen de l'inductance sans nécessiter un estimateur par mode de fonctionnement, et sans formuler un modèle mathématique complexe pour le système. Les estimations sont calculées à partir de l'historique des entrées et sorties mesurées récentes, ainsi qu'un ensemble de données de mesures préparées à partir d'expériences réalisées sur le système dans différentes conditions de fonctionnement. La structure du problème est exploitée pour obtenir une implémentation parallèle de l'algorithme fonctionnant sur une GPU (graphics processing unit), et une technique de réduction de la dimension est utilisée pour améliorer les performances en temps réel.

L'article est organisé comme suit : la section 2. présente l'énoncé du problème, la section 3. introduit les concepts de base de filtrage optimal pour l'estimation de l'état. La section 4. présente les résultats expérimentaux pour un convertisseur de puissance SEPIC. Enfin, la section 5. propose une brève discussion des résultats et quelques perspectives pour les travaux futurs.

2. Énoncé du Problème

Un convertisseur de puissance commuté peut être modélisé en considérant toutes les topologies possibles de circuits obtenues à partir des différents états de conduction et de blocage de ses composants à commutation. Ces configurations sont représentées par un système d'équations algèbro-différentielles linéaires commutées :

$$\begin{aligned}
 \mathbf{P}_{\sigma(t)} \dot{\mathbf{x}}(t) &= \mathbf{A}_{\sigma(t)} \mathbf{x}(t) + \mathbf{B}_{\sigma(t)} \mathbf{u}(t) + \mathbf{B}_x w(t) \\
 \mathbf{y}(t) &= \mathbf{C}_{\sigma(t)} \mathbf{x}(t) + \mathbf{D}_{\sigma(t)} \mathbf{u}(t) + \mathbf{B}_y w(t)
 \end{aligned} \tag{1}$$

où $\mathbf{x}(t) \in \mathbb{R}^{n_x}$ représente l'état, $\mathbf{u}(t) \in \mathbb{R}^{n_u}$ l'entrée et $\mathbf{y}(t) \in \mathbb{R}^{n_y}$ la sortie. Les termes $\mathbf{B}_x w(t)$ et $\mathbf{B}_y w(t)$ correspondent respectivement au bruit de processus et au bruit de mesure. Les matrices du système \mathbf{P}_σ , \mathbf{A}_σ , \mathbf{B}_σ , \mathbf{C}_σ , \mathbf{D}_σ sont sélectionnées en fonction du mode de système $\sigma(t) \in I$, où I est un ensemble d'indices fini. Un seul mode de système est actif à chaque instant, et cela dépend des états des commutateurs contrôlés $\mathbf{s}(t)$ et non contrôlés $\boldsymbol{\delta}(t)$: $\sigma(t) = g(\mathbf{s}(t), \boldsymbol{\delta}(t))$, $\mathbf{s}(t) \in \{0, 1\}^{n_s}$, $\boldsymbol{\delta}(t) \in \{0, 1\}^{n_\delta}$. L'état des commutateurs non contrôlés dépend des états du système et des entrées : $\boldsymbol{\delta}(t) = h(\mathbf{x}(t), \mathbf{u}(t))$. Cette interaction entre les variables continues et discrètes dans le système produit un système dynamique hybride. Le contrôle et l'observation de cette classe de systèmes sont assez complexes et font actuellement l'objet d'efforts de recherche actifs.

Objectif: Considérons le système décrit par l'équation (1) et supposons que les matrices \mathbf{P}_σ , \mathbf{A}_σ , \mathbf{B}_σ , \mathbf{C}_σ , \mathbf{D}_σ , \mathbf{B}_x , \mathbf{B}_y sont inconnues. A partir des mesures en temps discret de \mathbf{u} , \mathbf{y} et \mathbf{s} , il s'agit de donner des estimations en temps discret \hat{x} de l'état non mesuré x .

3. Filtrage Optimal pour l'Estimation d'État de Systèmes Inconnus

L'approche suivante est basée sur l'analyse d'intervalle pour l'identification de systèmes non linéaires [6], [7], [8]. Alors que les méthodes d'identification traditionnelles nécessitent certaines hypothèses a priori sur la classe du système (linéaire, bilinéaire, polynomiale, etc.), cette approche nécessite des hypothèses moins restrictives, sous forme de limites sur les gradients de fonction. Considérons le système non linéaire en temps discret

$$\begin{aligned}
 \mathbf{x}_{k+1} &= \mathbf{F}(\mathbf{x}_k, \mathbf{u}_k, \mathbf{d}_k, w_k) \\
 \mathbf{y}_k &= \mathbf{G}(\mathbf{x}_k, \mathbf{u}_k, \mathbf{d}_k, w_k)
 \end{aligned} \tag{2}$$

où $\mathbf{x}_k \in \mathbb{R}^{n_x}$ correspond à l'état, $\mathbf{d}_k \in \mathbb{R}^{n_d}$ à l'entrée contrôlée, $\mathbf{u}_k \in \mathbb{R}^{n_u}$ à l'entrée non contrôlée, $\mathbf{y}_k \in \mathbb{R}^{n_y}$ à la sortie et w_k au bruit. Un estimateur causal pour x_k est une fonction f qui associe les m valeurs mesurées passées de $\{\tilde{\mathbf{d}}, \tilde{\mathbf{y}}, \tilde{\mathbf{u}}\}$ à une estimation \hat{x}_k :

$$\hat{x}_k = f(\tilde{\mathbf{d}}_k, \tilde{\mathbf{y}}_k, \tilde{\mathbf{u}}_k, \dots, \tilde{\mathbf{d}}_{k-m+1}, \tilde{\mathbf{y}}_{k-m+1}, \tilde{\mathbf{u}}_{k-m+1}). \tag{3}$$

Cet estimateur existe si le système (2) est observable. L'objectif est d'obtenir un filtre causal avec une petite erreur d'estimation $x_k - \hat{x}_k$. La structure du filtre dans ce cas est une réponse impulsionnelle finie non linéaire (NFIR). Cette méthode est optimale dans le sens de l'approximation d'une fonction de filtre f telle que l'erreur d'estimation du pire cas soit minimisée. Cela fournit un moyen de calculer non seulement l'estimation de l'état mais aussi de quantifier l'incertitude associée au processus d'estimation. Un avantage de cette méthode est que l'estimateur NFIR considéré a la garantie d'être stable lorsque les entrées et les sorties du système sont bornées (BIBO).




Figure 1: Diagramme schématique du convertisseur SEPIC.

Considérons le filtre $\hat{x}_k = f(\tilde{\varphi}_k)$ où le régresseur $\tilde{\varphi}_k = [\tilde{\mathbf{d}}_k^m; \tilde{\mathbf{y}}_k^m; \tilde{\mathbf{u}}_k^m]$ correspond à une concaténation en vecteur colonne des m valeurs mesurées les plus récentes sur le système $\{\tilde{\mathbf{d}}, \tilde{\mathbf{y}}, \tilde{\mathbf{u}}\}$. Le processus de synthèse de l'estimateur consiste à trouver une approximation \hat{f} du filtre optimal inconnu f^0 (voir la définition 2 dans [7]) en utilisant l'ensemble de données $\mathcal{D} = \{\tilde{\varphi}_i, \tilde{x}_i, i = 1, 2, \dots, N\}$. Supposons que la fonction de filtre f appartient à l'ensemble :

$$\mathcal{F}(\gamma) = \{f \in C^1 : \|f'(\varphi)\| \leq \gamma, \forall \varphi \in \Phi\} \quad (4)$$

où f' est le gradient de f et $\Phi \subseteq \mathbb{R}^{(n_d+n_y+n_u)m}$ est le domaine du régresseur. Étant donné un ensemble de N échantillons de $\tilde{x}_i, \tilde{\varphi}_i$, l'ensemble des filtres réalisables (FFS) est défini comme :

$$FFS \doteq \{f \in \mathcal{F}(\gamma) : |\tilde{x}_i - f(\tilde{\varphi}_i)| \leq \varepsilon, i = 1, \dots, N\}. \quad (5)$$

Cet ensemble correspond au plus petit ensemble contenant f^0 , ou de façon équivalente, l'ensemble de tous les systèmes cohérents avec les informations préalables et les données mesurées. Le problème ici consiste à choisir γ et ε de telle manière que l'ensemble FFS ne soit pas vide. Les bornes de pire cas pour l'estimation sont données par :

$$\bar{f}(\tilde{\varphi}_k) = \min_{i=1, \dots, N} (\tilde{x}_i + \varepsilon + \gamma \|\tilde{\varphi}_k - \tilde{\varphi}_i\|) \quad (6a)$$

$$\underline{f}(\tilde{\varphi}_k) = \max_{i=1, \dots, N} (\tilde{x}_i - \varepsilon - \gamma \|\tilde{\varphi}_k - \tilde{\varphi}_i\|) \quad (6b)$$

où γ et ε sont des paramètres appris dans la procédure hors ligne décrite dans [9]. Le résultat suivant est utile pour vérifier la validité des données a priori :

Théorème 1:

- 1) Une condition nécessaire pour que l' FFS ne soit pas vide est $\bar{f}(\tilde{\varphi}_i) \geq \tilde{x}_i - \varepsilon, i = 1, \dots, N$.
- 2) Une condition suffisante pour que l' FFS ne soit pas vide est $\bar{f}(\tilde{\varphi}_i) > \tilde{x}_i - \varepsilon, i = 1, \dots, N$.

Preuve 1: Voir [6].

En utilisant ces conditions, les valeurs de γ et ε peuvent être correctement choisies. Une procédure pour y parvenir est présentée dans [6]. Spécifiquement, pour chaque valeur de ε , nous pouvons trouver une valeur limite γ^* séparant la région où $FFS = \emptyset$ de la région où $FFS \neq \emptyset$. Par conséquent, si une estimation pour ε est disponible, il est raisonnable de choisir γ comme une valeur légèrement supérieure à $\gamma^*(\varepsilon)$. En utilisant ces paramètres, le filtre direct (DF) est défini de la manière suivante :

$$\hat{x}_k = f_c(\tilde{\varphi}_k) \doteq \frac{1}{2} [\bar{f}(\tilde{\varphi}_k) + \underline{f}(\tilde{\varphi}_k)]. \quad (7)$$

4. Exemple d'application : Convertisseur SEPIC

Considérons le convertisseur SEPIC présenté dans la Fig. 1. Un signal PWM avec un rapport cyclique contrôlé est utilisé pour piloter l'interrupteur en boucle ouverte. Le vecteur d'état est $x = [I_{L1}, V_{C1}, I_{L2}, V_{C2}]^T$. Le modèle linéaire commuté du convertisseur SEPIC dans l'équation (1) est représenté par les matrices suivantes :

$$\mathbf{A}_{s(t), \delta(t)} = \begin{bmatrix} -R_{L1} - \beta R_{L2} & s-1 & 0 & s\delta - \delta \\ 1-s & s\delta & s-s\delta & s\delta \\ \beta & -s & \beta - R_{L2}(s+\delta-s\delta) & \delta-s\delta \\ \delta-s\delta & 0 & -\delta & -1/R_o \end{bmatrix}, \quad \mathbf{B}_{s(t), \delta(t)} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \quad \mathbf{P}_{s(t), \delta(t)} = \begin{bmatrix} L_1 & 0 & \beta L_1 & 0 \\ 0 & (1-s\delta)C_1 & 0 & 0 \\ 0 & 0 & (s+\delta-s\delta)L_2 & 0 \\ 0 & s\delta C_1 & 0 & C_2 \end{bmatrix}, \\
 \mathbf{C}_{s(t), \delta(t)} = [0 \ 0 \ 0 \ 1], \quad \mathbf{D}_{s(t), \delta(t)} = 0,$$

où $s(t) \in \{0, 1\}$ est le signal binaire qui contrôle la commutation du MOSFET, $\delta(t) \in \{0, 1\}$ est une variable binaire qui représente l'état non contrôlé de la diode et $\beta = (1-s)(1-\delta)$. R_{L1}, R_{L2} sont les résistances internes

équivalentes de l'inducteur et R_o est la résistance de charge. Les paramètres utilisés pour le convertisseur SEPIC dans les tests expérimentaux sont les suivants : $E = 20$ V, $L_1 = 2.3$ mH, $C_1 = 190$ μ F, $L_2 = 330$ μ H, $C_2 = 190$ μ F, $R_{L1} = 2.134$ Ω , $R_{L2} = 0.234$ Ω , $R_o = 22$ Ω , $f_{pwm} = 20$ kHz.

La conception d'un observateur pour estimer les variables d'état dans ce modèle hybride n'est pas une tâche facile. Par conséquent, nous utilisons l'approche introduite dans la section 3. pour concevoir des filtres directs permettant d'estimer le courant I_{L1k} à partir de mesures bruitées échantillonnées de la tension d'entrée $u_k = E_k$, de la tension de sortie $y_k = V_{C2k}$ et de la connaissance du rapport cyclique contrôlé d_k . Un ensemble de données \mathcal{D} est obtenu en appliquant un signal binaire pseudo-aléatoire modulé en amplitude (PRBS) à l'entrée du rapport cyclique du convertisseur SEPIC en boucle ouverte et en mesurant la tension de sortie tout en maintenant une tension d'entrée constante. Le signal PRBS maintient une valeur constante aléatoire pendant une durée de séjour donnée T_d . Les signaux sont générés de manière aléatoire en définissant des durées de séjour minimales et maximales $T_{d,min}$, $T_{d,max}$ pour les ensembles de données d'entraînement et de test. Les niveaux minimum et maximum du signal de rapport cyclique appliqué au convertisseur sont sélectionnés dans une large plage pour forcer le fonctionnement dans les régions CCM et DCM.

Les résultats présentés dans les sous-sections suivantes sont basés sur l'acquisition des formes d'onde détaillées du courant et de la tension du convertisseur SEPIC pour les signaux PRBS conçus. Ces signaux sont ensuite moyennés et rééchantillonnés à une fréquence suffisamment élevée f_{rs} pour capturer le comportement à basse fréquence du convertisseur. Un schéma de mise à l'échelle est appliqué à l'ensemble de données des régresseurs, comme décrit dans [6], pour améliorer les performances de l'estimation. De plus, l'analyse en composantes principales (PCA) a été utilisée pour mapper les régresseurs dans un espace de dimension inférieure afin de réduire davantage le coût de calculs.

4.1 Résultats expérimentaux

Plusieurs essais expérimentales sont effectuées en appliquant différents signaux de rapport cyclique PRBS en boucle ouverte au banc d'essai expérimental SEPIC, et en mesurant toutes les variables avec un oscilloscope à $f_s = 2$ MSa/s. Ensuite, les signaux acquis sont rééchantillonnés à $f_{rs} = 4$ KSa/s. La méthode présentée dans la section 3. est utilisée pour préparer quatre ensembles de données de régresseurs différents avec différentes valeurs de $T_{d,min}$ et $T_{d,max}$. Pour chaque ensemble de données, $N = 10000$ régresseurs d'entraînement avec une longueur totale de $3m = 60$ sont préparés à l'aide de 5 captures de 500 ms, et chacun des 20 signaux de test est préparé en prenant 3 captures de 500 ms.

Deux implémentations différentes du filtre direct sont comparées. Le filtre direct de base décrit par l'équation (7) est le DF. Le filtre direct avec jeu de données réduit par PCA (DFPCA) met en œuvre le même estimateur, mais en utilisant un jeu de données formé par des régresseurs de dimension réduite, obtenus à l'aide de l'analyse en composantes principales (PCA). Les performances de DF et DFPCA sont comparées par rapport à d'autres approches d'estimation : le filtre de Kalman étendu (EKF), le filtre de particules (PF) et les réseaux neuronaux (NN). Pour les approches basées sur le modèle (EKF, PF), le modèle moyen non linéaire du convertisseur SEPIC en CCM est utilisé. Le PF calcule l'évolution de 50 particules en utilisant la méthode d'Euler pour 10 sous-intervalles à chaque étape d'échantillonnage. Pour les approches basées sur les données (DF, DFPCA, NN), un jeu de données avec $N = 10000$ régresseurs et une longueur totale de régresseur de $3m = 60$ a été obtenu par simulation. Ce jeu de données a été utilisé pour apprendre les paramètres (ε, γ) pour le DF, et pour former un réseau neuronal à propagation avant avec $3m$ entrées et 1 sortie. Après quelques tests, les meilleures performances ont été obtenues avec 30 neurones dans la couche cachée.

La figure 2 montre la comparaison des performances de tous les estimateurs implémentés par rapport aux mesures d'erreur suivantes :

$$\begin{aligned}
 \text{Erreur relative: } RAE &= 100 \|x - \hat{x}\|_1 / \|x - \bar{x}\|_1 \\
 \text{Erreur quadratique relative: } RRSE &= 100 \|x - \hat{x}\|_2 / \|x - \bar{x}\|_2 \\
 \text{Erreur relative maximale: } RWCE &= 100 \|x - \hat{x}\|_\infty / \|x - \bar{x}\|_\infty
 \end{aligned}$$

Il est à noter que les estimateurs basés sur les données ont de meilleures performances que ceux basés sur le modèle. Cependant, les performances du NN sont moins bonnes que celles du DF et du DFPCA. En particulier, la mesure RWCE est nettement moins bonne que les autres, ce qui indique la présence de valeurs aberrantes de grande amplitude. Cela peut être observé sur la figure 3, où l'estimation du NN présente de fortes quantités de bruit, en particulier dans les intervalles de temps $t = [1, 034, 1, 052]$ et $t = [1, 07, 1, 083]$, où l'entrée mesurée u et la sortie y montrent la plus grande variabilité. Les performances de l'estimateur DFPCA sont presque identiques à celles de l'estimateur DF.




Figure 2: Performance d'estimation (moyenne \pm écart type, 20 exécutions de test de 1,5 s chacune) pour le filtre direct (DF), le filtre direct avec jeu de données PCA (DFPCA), les réseaux neuronaux (NN), le filtre de Kalman étendu (EKF) et le filtre à particules (PF) avec 4 jeux de données expérimentaux différents ayant des temps $T_{d,\min}$ et $T_{d,\max}$ différents. $m = 20$, $N = 10000$, $\varepsilon = 0.1292$.




Figure 3: Résultats expérimentaux (de haut en bas) : Rapport cyclique d et limite CCM-DCM \bar{d} . Tension de sortie $y = V_{C2}$. Estimation du courant d'entrée I_{L1} avec le filtre direct (DF), le filtre direct avec jeu de données PCA (DFPCA), les réseaux neuronaux (NN), le filtre de Kalman étendu (EKF) et le filtre à particules (PF).

4.2 Résultats de performance pour l'implémentation parallèle

Le tableau I présente les résultats de performance des estimateurs DF et DFPCA en utilisant les quatre ensembles de données expérimentaux disponibles. La perte de performance moyenne du DFPCA par rapport au DF est présentée pour les trois mesures d'erreur. Le temps d'exécution moyen d'une itération de l'algorithme est indiqué pour deux implémentations différentes : CPU exécutant l'estimateur DF séquentiellement et GPU exécutant l'implémentation parallèle de l'estimateur DFPCA. L'amélioration des temps de calculs de l'implémentation GPU+PCA par rapport à l'implémentation CPU est également présentée. On peut remarquer que la performance d'estimation diminue de moins de 2% l'erreur absolue lors de l'utilisation de l'ensemble de données réduit. D'autre part, la vitesse de calcul est augmentée de plus de 6 fois, permettant d'obtenir des estimations à une fréquence de 4 kHz, correspondant au temps d'échantillonnage de l'ensemble de données expérimentales.

Ces résultats montrent que l'utilisation de jeux de données à dimensions réduites sur GPU offre un gain de vitesse de calcul qui compense les pertes d'estimation et permet une mise en œuvre réalisable de l'algorithme DF pour des applications en temps réel. Cependant, les expériences réalisées n'ont pas utilisé un système d'exploitation temps réel (RTOS), mais plutôt un système d'exploitation à usage général (GPOS). Par conséquent, une certaine gigue a été observée dans les estimations produites par l'algorithme DF. Cela peut rendre la méthode proposée inapplicable dans des applications nécessitant la satisfaction de contraintes de temporisation déterministes strictes. Le développement d'applications GPU en temps réel pour les systèmes de contrôle nécessite des considérations supplémentaires [10]. Le matériel utilisé pour ces tests est le Nvidia Jetson TX2, utilisant l'un des quatre cœurs de processeur ARM Cortex-A57 disponibles fonctionnant à 2,0 GHz, et le GPU Pascal fonctionnant à 1,12 GHz.

Tableau I: Comparaison des performances entre les implémentations DF et DFPCA sur CPU et GPU en utilisant un jeu de données réduit par PCA. $N = 10000$, longueur du régresseur dans le jeu de données original ($3m = 60$), longueur du régresseur dans le jeu de données réduit par PCA = 13.

Dataset	Mean performance loss (%)			Exec. time (ms) / speedup	
	RAE	RRSE	RWCE	CPU	GPU+PCA
DS1	1.5446	1.6832	3.0170	1.6410	0.2419 / 6.7847X
DS2	0.2641	0.8726	4.0489	1.6445	0.2434 / 6.7577X
DS3	0.6703	0.1592	6.4868	1.6491	0.2437 / 6.7660X
DS4	0.4993	0.7582	1.9521	1.6428	0.2443 / 6.7235X

5. Conclusion

Une méthode de conception d'estimateurs sans connaissance exacte du modèle du système a été présentée. Cette approche est utile pour l'estimation dans les convertisseurs de puissance fonctionnant à la fois en CCM et en DCM. En raison des changements dynamiques drastiques dans le comportement du système lors du passage de la frontière entre CCM et DCM, le modèle moyen ne fournit pas une bonne approximation. Cette méthode peut être appliquée aux convertisseurs de puissance et son efficacité est montrée pour le cas du convertisseur DC-DC SEPIC. Des résultats expérimentaux ont été présentés, montrant que cette approche fournit de bons résultats d'estimation par rapport à d'autres méthodes basées sur un modèle et des données. De plus, nous montrons qu'une implémentation en temps réel de l'algorithme du filtre direct est réalisable en utilisant une implémentation parallèle s'exécutant sur un GPU, et en appliquant une analyse en composantes principales pour réduire la taille des ensembles de données.

Les extensions futures de ce travail comprennent la mise en œuvre de l'algorithme du filtre direct sur une plateforme matérielle embarquée exécutant un système d'exploitation en temps-réel. De plus, il serait intéressant d'analyser la dépendance de la performance d'estimation dans l'espace des paramètres (m, N) pour différentes topologies de convertisseurs où le DCM est présent. Finalement, une investigation plus détaillée sur la perte de performance d'estimation due à la réduction de dimension de l'espace des régresseurs permettrait de mieux comprendre l'avantage de l'application de l'analyse en composantes principales dans ce contexte.

Références

- [1] M. Biglarbegan, S. J. Nibir, H. Jafarian, and B. Parkhideh, "Development of current measurement techniques for high frequency power converters," in 2016 IEEE International Telecommunications Energy Conference (INTELEC), 2016, pp. 1–7.
- [2] H. Zhou, C. Tan, and J. Fletcher, "Lossless bi-directional current sense circuit for low-voltage high-current dc/dc converters," in IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, 2018, pp. 1305–1308.
- [3] G. Cimini, G. Ippoliti, G. Orlando, and M. Pirro, "Current sensorless solution for pfc boost converter operating both in dcm and ccm," in 21st Mediterranean Conference on Control and Automation, 2013, pp. 137–142.
- [4] C. H. van der Broeck, R. W. De Doncker, S. A. Richter, and J. v. Bloh, "Unified control of a buck converter for wide-load-range applications," IEEE Transactions on Industry Applications, vol. 51, no. 5, pp. 4061–4071, 2015.
- [5] V. Spinu, M. Dam, and M. Lazar, "Observer design for dc/dc power converters with bilinear averaged model," IFAC Proceedings Volumes, vol. 45, no. 9, pp. 204–209, 2012, 4th IFAC Conference on Analysis and Design of Hybrid Systems. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1474667015371974>
- [6] M. Milanese and C. Novara, "Set membership identification of nonlinear systems," Automatica, vol. 40, no. 6, pp. 957–975, 2004. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0005109804000470>
- [7] C. Novara, F. Ruiz, and M. Milanese, "Direct filtering: A new approach to optimal filter design for nonlinear systems," IEEE Transactions on Automatic Control, vol. 58, no. 1, pp. 86–99, 2013.
- [8] F. Ruiz, C. Novara, and M. Milanese, "Direct design from data of optimal filters for lpv systems," Systems & Control Letters, vol. 59, no. 1, pp. 1–8, 2010. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167691109001339>
- [9] G. Becerra, F. Ruiz, D. Patino, M. T. Pham, and X. Lin-Shi, "Learning-based current estimation for power converters operating in continuous and discontinuous conduction modes," Mathematics and Computers in Simulation, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0378475423001155>
- [10] G. A. Elliott and J. H. Anderson, "Real-world constraints of gpus in real-time systems," in 2011 IEEE 17th International Conference on Embedded and Real-Time Computing Systems and Applications, vol. 2, 2011, pp. 48–54.