

Περίληψη

Υπάρχουν τρεις κύριες κατευθύνσεις στο σχεδιασμό συστημάτων ελέγχου διακριτού χρόνου που βασίζονται σε τεχνικές τεχνητών νευρωνικών δικτύων (ΝΔ). Πιο συγκεκριμένα είναι οι μεθοδολογίες ελέγχου βασισμένου σε μοντέλο πρόβλεψης (Model Predictive Control, στο εξής θα αναφέρεται ως MPC) [1], οι τεχνικές προσαρμοστικού ελέγχου (Adaptive Control) [2] και οι μεθοδολογίες ελέγχου βασισμένου σε αντίστροφο μοντέλο (Inverse Model Control) [3]. Η ενσωμάτωση του ΝΔ στο σχεδιασμό των MPCs είναι η πιο δημοφιλής προσέγγιση, κατά την οποία μεθοδολογίες νευρωνικών δικτύων χρησιμοποιούνται για την κατασκευή ενός μη-γραμμικού δυναμικού μοντέλου πρόβλεψης [4]. Συνήθως, τα μοντέλα νευρωνικών δικτύων αναπτύσσονται λόγω της έλλειψης μοντέλου βασικών εξισώσεων (First Principle Model), εφαρμόζοντας αλγόριθμους εκπαίδευσης σε ιστορικά δυναμικά δεδομένα εισόδου – εξόδου του συστήματος.

Το κύριο εμπόδιο στην εφαρμογή των μη-γραμμικών MPCs είναι ότι το πρόβλημα της μη-γραμμικής βελτιστοποίησης, που διαμορφώνεται σε κάθε διακριτή χρονική στιγμή, πρέπει να επιλυθεί σε πραγματικό χρόνο [5]. Ωστόσο, το διαθέσιμο διάστημα μεταξύ δύο συνεχόμενων χρονικών στιγμών μπορεί να μην είναι αρκετό, ακόμη και για να ικανοποιηθούν οι σαφώς μειωμένες απαιτήσεις ενός υποβέλτιστου (sub-optimal) MPC [6]. Για να ξεπεραστεί αυτό το πρόβλημα και να επεκταθεί η εφαρμογή των MPCs σε συστήματα με γρήγορη δυναμική, επινοήθηκε η έννοια του ρητού MPC (Explicit MPC), κατά την οποία η υπολογιστική επιβάρυνση του MPC μεταφέρεται εκτός της κανονικής λειτουργίας του συστήματος, υπολογίζοντας εκ των προτέρων το βέλτιστο νόμο ελέγχου του MPC ως συνάρτηση της τρέχουσας κατάστασης του συστήματος. Η λύση που προσφέρουν οι ρητοί MPC για γραμμικά συστήματα έχει εγγυημένη ακρίβεια [7], αλλά δυστυχώς, για την περίπτωση μη γραμμικών συστημάτων, έχουν αναπτυχθεί μόνο προσεγγιστικές μέθοδοι [8]. Ένα άλλο μειονέκτημα του ρητού MPC είναι ότι υποφέρει από την κατάρα της διαστατικότητας (curse of dimensionality) και, ειδικά σε προβλήματα υψηλής διαστατικότητας, η διαδικασία ανεύρεσης της σωστής περιοχής όπου ανήκει η τρέχουσα κατάσταση μπορεί να είναι πιο απαιτητική υπολογιστικά από την επίλυση του προβλήματος βελτιστοποίησης σε πραγματικό χρόνο. Η βελτίωση της υπολογιστικής ταχύτητας είναι το πιο σημαντικό ζήτημα της έρευνας σήμερα στη βιβλιογραφία των MPCs [5], αλλά η ανάπτυξη εξειδικευμένων αλγορίθμων γρήγορης βελτιστοποίησης [9] περιορίζεται σε γραμμικά συστήματα ή σε συστήματα που γραμμικοποιούνται σε πραγματικό χρόνο [10].

Στην εργασία αυτή παρουσιάζεται ένα νέο σχήμα μη-γραμμικού αυτομάτου ελέγχου, βασισμένο στην προσέγγιση της αντίστροφης δυναμικής του υπό έλεγχο συστήματος, με χρήση νευρωνικών δικτύων αρχιτεκτονικής ακτινικής συμμετρίας βάσης (Radial Basis Function, RBF). Το δίκτυο RBF εκπαιδεύεται με τον αλγόριθμο Ασαφών Μέσων (Fuzzy Means) [11, 12] χρησιμοποιώντας αποκλειστικά και μόνο πειραματικά δεδομένα εισόδου – εξόδου από την κανονική λειτουργία και, στη συνέχεια, εφαρμόζεται ως νόμος ελέγχου του συστήματος. Όσον αφορά το υπολογιστικό φορτίο, η προσέγγιση του άμεσου αντίστροφου ελέγχου είναι πολύ αποτελεσματική, δεδομένου ότι απαιτεί μόνο τον υπολογισμό μιας μη-γραμμικής συνάρτησης.

Ο αντίστροφος νευρωνικός ελεγκτής που ενσωματώνει το μοντέλο του συστήματος είναι επιρρεπής σε προβλήματα όπως το φαινόμενο της παρέκτασης (Extrapolation), που εμφανίζεται σε όλες τις τεχνικές μοντελοποίησης τύπου black-box. Αυτό το φαινόμενο έχει σαν αποτέλεσμα την παραγωγή αναξιόπιστων προβλέψεων για περιοχές του χώρου εισόδου που δεν καλύπτονται επαρκώς από πειραματικά δεδομένα και, έτσι, μπορεί να χειροτερέψει αισθητά την απόδοση του ελεγκτή. Για την αποφυγή του extrapolation στις προβλέψεις του μοντέλου RBF, μια ιδέα δανεισμένη από το πεδίο της Χημειομετρίας (Chemometrics), συγκεκριμένα το Πεδίο Καταλληλότητας (Applicability Domain) [13], ενσωματώνεται στο προτεινόμενο πλαίσιο. Το Πεδίο Καταλληλότητας εκφράζεται, στην παρούσα εργασία, από την τιμή μόχλευσης, που είναι ανάλογη του στατιστικού δείκτη Hotelling T^2 και της απόστασης Mahalanobis. Πιο συγκεκριμένα, η έννοια του AD χρησιμοποιείται για την εύρεση του άνω και κάτω ορίου της επιθυμητής τιμής, που διασφαλίζουν την αξιόπιστη παρεμβολή.

Προκειμένου να ληφθούν υπόψη ανακρίβειες στα δεδομένα εκπαίδευσης, τα όρια που ορίζει το AD στενεύουν με τη χρήση ενός συντελεστή περιορισμού, ο οποίος χρησιμοποιείται ταυτόχρονα και για τη βαθμονόμηση του ελεγκτή, έχοντας την ικανότητα να κάνει τον ελεγκτή συντηρητικό ή, εάν αυτό απαιτείται, επιθετικό στις δράσεις του προσπαθώντας να οδηγήσει το σύστημα προς την επιθυμητή τιμή. Επιπλέον, εισάγεται ένας παράγοντας διόρθωσης σφάλματος, που επιτρέπει στον αντίστροφο νευρωνικό ελεγκτή να λαμβάνει υπ' όψιν σφάλματα του μοντέλου και αβεβαιότητες στις παραμέτρους του συστήματος, καθώς και να απορρίπτει εξωτερικές διαταραχές, μηδενίζοντας σε κάθε περίπτωση το σφάλμα σε μόνιμη κατάσταση. Ο παράγοντας διόρθωσης σφάλματος λειτουργεί με την ίδια αρχή του ολοκληρωτικού κομματιού ενός ιδανικού PID ελεγκτή, το οποίο χρησιμοποιεί το ολοκλήρωμα του ιστορικού των σφαλμάτων για να διορθώσει κατάλληλα την τιμή της εξόδου. Η χρησιμοποίηση των προηγούμενων σφαλμάτων αναγκάζει τις δράσεις του ελεγκτή να αλλάζουν συνεχώς, έως ότου το προηγούμενο σφάλμα να γίνει μηδέν.

Η προτεινόμενη προσέγγιση εφαρμόζεται στον αυτόματο έλεγχο δυο διαφορετικών μη γραμμικών συστημάτων και πιο συγκεκριμένα ενός κινητήρα συνεχούς ρεύματος και ενός αντιδραστήρα συνεχούς έργου πλήρους ανάδευσης (CSTR) με πολλαπλά σημεία ισορροπίας, εκ των οποίων το ένα είναι ασταθές. Τέλος, η σύγκριση με άλλα είδη ελεγκτών σε διαφορετικά προβλήματα ελέγχου που συμπεριλαμβάνουν παρακολούθηση επιθυμητής τιμής, απόρριψη εξωτερικής διαταραχής και αβεβαιότητες στις παραμέτρους του συστήματος, καταδεικνύουν τα πλεονεκτήματα του προτεινόμενου ελεγκτή, ο οποίος εμφανίζεται να υπερέχει των ανταγωνιστών του σε δείκτες όπως η ταχύτητα απόκρισης, το overshoot και ο χρόνος αποκατάστασης.

Τα αποτελέσματα της παρούσας εργασίας δημοσιεύτηκαν στο διεθνές επιστημονικό περιοδικό *Journal of Process Control* [14]. Τα σχέδια για μελλοντική έρευνα περιλαμβάνουν την επέκταση της προτεινόμενης προσέγγισης, προκειμένου να σχεδιαστεί ένας αντίστροφος νευρωνικός ελεγκτής κατάλληλος για τον έλεγχο συστημάτων πολλαπλών εισόδων – πολλαπλών εξόδων (Multiple Input – Multiple Output).

Βιβλιογραφία

- [1] A. Alexandridis, H. Sarimveis, K. Ninos, A radial basis function network training algorithm using a non-symmetric partition of the input space – Application to a model predictive control configuration, *Adv. Eng. Softw.*, 42 (2011) 830-837.
- [2] A. Alexandridis, H. Sarimveis, Nonlinear adaptive model predictive control based on self-correcting neural network models, *AIChE J.*, 51 (2005) 2495-2506.
- [3] M. Mohammadzaheri, L. Chen, S. Grainger, A critical review of the most popular types of neural control, *Asian J. Control*, 14 (2012) 1-11.
- [4] B.M. Akesson, H.T. Toivonen, A neural network model predictive controller, *J. Process Contr.*, 16 (2006) 937-946.
- [5] J.H. Lee, Model Predictive Control: Review of the three decades of development, *Int. J. Control Autom.*, 9 (2011) 415-424.
- [6] K. Graichen, A. Kugi, Stability and incremental improvement of suboptimal MPC without terminal constraints, *IEEE Trans. Automat. Contr.*, 55 (2010) 2576-2580.
- [7] P. Patrinos, H. Sarimveis, A new algorithm for solving convex parametric quadratic programs based on graphical derivatives of solution mappings, *Automatica*, 46 (2010) 1405-1418.
- [8] A. Grancharova, T.A. Johansen, Computation, approximation and stability of explicit feedback min–max nonlinear model predictive control, *Automatica*, 45 (2009) 1134-1143.

- [9] Y. Wang, S. Boyd, Fast model predictive control using on-line optimization, *IEEE Trans. Automat. Contr.*, 18 (2010) 267-278.
- [10] M. Lawrynczuk, On improving accuracy of computationally efficient nonlinear predictive control based on neural models, *Chem. Eng. Sci.*, 66 (2011) 5253-5267.
- [11] A. Alexandridis, H. Sarimveis, G. Bafas, A new algorithm for online structure and parameter adaptation of RBF networks, *Neural Netw.*, 16 (2003) 1003-1017.
- [12] A. Alexandridis, E. Chondrodima, H. Sarimveis, Radial Basis Function Network Training Using a Nonsymmetric Partition of the Input Space and Particle Swarm Optimization, *IEEE Trans. Neural Netw. Learn. Syst.*, 24 (2013) 219-230.
- [13] F. Sahigara, K. Mansouri, D. Ballabio, A. Mauri, V. Consonni, R. Todeschini, Comparison of different approaches to define the applicability domain of QSAR models, *Molecules*, 17 (2012) 4791-4810.
- [14] A. Alexandridis, M. Stogiannos, A. Kyriou, H. Sarimveis, An offset-free neural controller based on a non-extrapolating scheme for approximating the inverse process dynamics, *J. Process Contr.*, 23 (2013) 968-979.