

ALGORITM PENTRU OPTIMIZAREA PROCESELOR TERMODINAMICE PE BAZA TEORIEI REȚELELOR NEURONALE CU FOLOSIREA LOGICII FUZZY

Prof. dr. ing. Gheorghe DUMITRU

UNIVERSITATEA „Dunărea de Jos” Galați

Abstract. In paper there are presented optimization problem of the thermodynamic processes from actual thermodynamic systems considering an increased number of independent variable with using neural network theory and fuzzy logic. There are used as optimization criterion exergetic efficiency or, for complex systems that as energetic systems with machines and thermal equipments, the minimum specific costs in their exploiting. There are presented an algorithm for the learning equivalent neural network and the possibilities to verify experimentally using Disa Elektronik, National Instruments apparatus and PC signal processing.

1. INTRODUCERE

Procesele termodinamice din sistemele termodinamice (S.T.) des întâlnite sunt procese complexe fizice, chimice, și/sau biologice, caracterizate de un număr mare de parametri și anume de un număr infinit de parametri independenți, în cazul considerării sistemului termodinamic care suferă procese în cadrul modelului matematic al mediului continuu compresibil și uneori vâscos [8], [22]. Deseori se consideră sistemele termodinamice în care au loc procese termodinamice caracterizate de un număr finit de parametri independenți, corespunzători contactelor distințe ale acestuia cu exteriorul, S.T. fiind în acest caz de tipul cu *parametri concentrați*, la care perturbațiile transmise din exterior se propagă instantaneu [1]–[3], [12]. În general S.T. trebuie considerate sisteme dinamice infinit dimensionale sau finit dimensionale, avându-se în vedere desfășurarea dinamică a proceselor, care de fapt sunt comandate (conduse) în sensul realizării lor optimale. Dacă se consideră noțiunea de S.T. ca fiind o porțiune din univers formată dintr-o mulțime finită de corperi și câmpuri din el, în interacțiune cu mediul exterior, prin intermediul frontierei înțeleasă prin noțiunea de suprafață geometrică, numită după Ludwig Prandtl *suprafață de control* ce închide spațiul de control sau *volumul de control* al S.T. și care are proprietățile care intră în definirea univocă a S.T., rezultă creșterea numărului de variabile ce influențează procesele termodinamice din S.T. Descrierea proceselor din S.T. poate fi făcută față de sistemele de referință Lagrange și/sau Euler, în cazul valabilității principiului relativității al lui Galileu sau a principiului relativității restrâns al lui Einstein. Pentru evaluarea proceselor termodinamice se pot folosi : • modele deterministe [7], [12], [16], [21]; • modele stocastice [5], [6], [13], [15], [24], [25]; • modele folosite în realizarea sistemelor de inteligență artificială [9], [23]. Primele două tipuri de modele folosesc ecuațiile fizice matematice bazate pe logica bivalentă, modele rigide și sensibile la perturbații, fiind susceptibile la acumularea de erori în

evaluarea proceselor reale, pe cătă vreme modelele inteligenței artificiale folosesc modelele rețelelor neuronale artificiale fără, sau cu abordarea pe baza logicii fuzzy, modele care conferă „consistență umană” acestora. Procesele termodinamice au loc în cele mai multe sisteme tehnice și în toate sistemele biologice necesitând întotdeauna controlul lor în sensul desfășurării lor optime, în concordanță cu scopul urmărit în funcționarea acestora. Din [10], [11], rezultă avantajele oferite de modelele inteligenței artificiale față de modelele deterministe și stocastice, legate de considerarea unui număr sporit de variabile independente și de folosirea unor algoritmi mai simpli în conducerea lor optimală.

2. ALGORITM PENTRU OPTIMIZAREA PROCESELOR TERMODINAMICE PE BAZA TEORIEI REȚELELOR NEURONALE

Rețelele neuronale artificiale pentru un sistem tehnic oarecare și deci și pentru un sistem termodinamic (S.T.) sunt modele de rețele de neuroni conectați prin intermediul unor sinapse ajustabile numite simplu *rețele neuronale* (R.N.). Instruirea R.N. poate fi realizată supervizată sau nesupervizată, instruire necesară găsirii dependențelor corecte între mărimile de intrare și mărimile de ieșire din rețea. Modelele conexione ale inteligenței artificiale sunt considerate modele de desidere largă. Pe baza lor s-au construit până în prezent algoritmi utilizati în special în controlul optimal al sistemelor de reglare automată [4], [14], [22], [26]. Se consideră cazul rețelei neuronale cu p neuroni, care, în general, sunt conectați fiecare cu ceilalți. Astfel neuronul i are $p - 1$ intrări care provin de la $p - 1$ neuroni și intrări din exterior în număr de $n - p + 1$ intrări. Deci neuronul i are n intrări date sub forma $\tilde{x}^i(x_1^i, x_2^i, \dots, x_n^i)$, cu ponderile $\tilde{w}^i(w_1^i, w_2^i, \dots, w_n^i)$, în care $w_j^i > 0, j = 1, n$ – pentru ponderi excitatoare și $w_j^i < 0, j = 1, n$ – pentru ponderi inhibitoare. Starea neuronului i este data de acțiunile celorlalți neuroni și de acțiunile externe:

$$s^i = \sum_{j=1}^n w_j^i x_j^i, \quad j = 1, n. \quad (1)$$

Dacă se notează cu t^i pragul de excitare al neuronului i atunci funcția de răspuns a neuronului de forma $f^i : R \rightarrow R$, se poate scrie:

$$y^i = f^i \left(\sum_{j=1}^n w_j^i x_j^i + t^i \right), \quad j = 1, n; \quad (2)$$

sau cu notațiile $w_{n+1}^i = t^i$, $x_{n+1}^i = 1$, activarea totală a neuronului i devine:

$$s^i = \sum_{j=1}^{n+1} w_j^i x_j^i, \quad j = 1, n; \quad (3)$$

iar funcția de ieșire a neuronului i devine:

$$y^i = f^i(s^i) = f^i(\vec{v}^{iT} * \vec{x}^i), \quad i = 1, p; \quad (4)$$

în care: $\vec{x}^{iT} = [x_1^i, \dots, x_{n+1}^i]^T$ este transpusul vectorului de stare al neuronului i ; $\vec{v}^{iT} = [w_1^i, \dots, w_{n+1}^i]$ – transpusul vectorului pondere asociat neuronului i ; f^i – funcția neuronală, funcția de ieșire sau funcția de activare a neuronului i .

Funcția neuronală poate fi adoptată de diverse forme: funcția prag, în cazul utilizării logicii bivalente; funcția signum, în cazul utilizării logicii bivalente; funcții sigmoidale, folosite în cazul utilizării logicii multivalente (continue), cu formele:

$$\begin{aligned} f(s^i) &= \frac{1}{1 + e^{-ks^i}}, \quad k > 0; \\ f(s^i) &= \frac{2}{1 + e^{-ks^i}} - 1, \quad k > 0; \\ f(s^i) &= \frac{e^{ks^i} - e^{-ks^i}}{e^{ks^i} + e^{-ks^i}}, \quad k > 0. \end{aligned} \quad (5)$$

Rețeaua neurală considerată global reprezintă un sistem dinamic, definindu-se pentru întregă rețea cu p neuroni matricea de stare și matricea de conexiuni ale rețelei, la timpul considerat, respectiv sub formele:

$$X = \begin{bmatrix} x_1^1, x_2^1, \dots, x_{n+1}^1 \\ x_1^2, x_2^2, \dots, x_{n+1}^2 \\ \vdots \\ x_1^p, x_2^p, \dots, x_{n+1}^p \end{bmatrix}; \quad W = \begin{bmatrix} w_1^1, w_2^1, \dots, w_{n+1}^1 \\ w_1^2, w_2^2, \dots, w_{n+1}^2 \\ \vdots \\ w_1^p, w_2^p, \dots, w_{n+1}^p \end{bmatrix} \quad (6)$$

și transpusul vectorului de activare la momentul considerat: $\vec{S}^T = [s^1, \dots, s^p]$ sau $\vec{S} = W * X^T$. Pentru studiul dinamicii rețelei vom considera ca parametru timpul rezultând: starea de activare totală a neuronului i la momentul t , $s^i(t) = \sum_{j=1}^{n+1} w_j^i(t) * x_j^i(t)$; mărimea de ieșire (semnalul) a neuronului i la timpul $t + 1$:

$$y^i(t+1) = f^i(s^i(t)) = f^i(\vec{v}^{iT}(t) * \vec{x}^i(t)); \quad i = 1, p. \quad (7)$$

Dacă notăm cu \vec{F} funcția vectorială a rețelei având drept componente valorile funcțiilor neuronale f^i , $i = 1, p$,

putem scrie pentru transpusa funcției vectoriale relația $\vec{F}(\vec{S}) = [f^1(s^1), \dots, f^p(s^p)]^T$ și dacă notăm transpusul vectorului mărimilor de ieșire ale neuronilor cu $\vec{Y} = [y^1, \dots, y^p]$, atunci ecuația de mișcare a rețelei se poate scrie sub formă:

$$\vec{Y}(t+1) = \vec{F}(\vec{S}(t)) = \vec{F}(W(t) * X^T(t)). \quad (8)$$

Rețelele neuronale asociate proceselor termodynamice complexe ce au loc în sistemele termodynamice transformă mărimile de intrare în mărimi de ieșire pentru întregul sistem termodynamic, adică mărimile $x(x_1, x_2, \dots, x_n)$, $x \in R^n$, în mărimile $y(y_1, y_2, \dots, y_m)$, $y \in R^m$. Adoptarea rețelei neuronale asociate proceselor din sistemele termodynamice este euristică și depinde de scopul urmărit pentru optimizarea acestora, în conformitate cu cele două cazuri care se pot considera: • cazul proiectării optimale a proceselor termodynamice, cu considerarea evidentă și a caracteristicilor incintei (spațiului de control în care au loc), ca variabile independente, ce intră în definirea sistemului termodynamic; • cazul conducerii optimale a proceselor termodynamice (controlului proceselor termodynamice), cu considerarea evidentă și a caracteristicilor date ale incintei (spațiului de control în care au loc), ce intră în definirea sistemului termodynamic. Desigur că, în cele două situații, variabilele independente care determină criteriile de optimizare sunt diferite și trebuie considerate și regăsite corespunzător în rețelele neuronale echivalente ale sistemelor termodynamice luate în studiu. Ca urmare numărul și semnificațile mărimilor de intrare vor fi diferite, iar mărimile de ieșire vor fi cele date și de contactele distincte admise ca independente ale sistemului termodynamic considerat cu parametri concentrați pe subsistemele acestuia.

Drept criterii de optimizare pot fi adoptate: randamentul exergetic al proceselor din sistemul termodynamic considerat și costurile specifice ale proceselor termodynamice din sistemul termodynamic considerat. Randamentul exergetic al proceselor termodynamice analizate poate fi considerat prin:

$$\eta_{ex} = \frac{\dot{E}_{ex, produsă}}{\dot{E}_{ex, consumată}}, \quad (9)$$

în care: $\dot{E}_{ex, produsă}$ este fluxul de energie produs în scopul urmărit de procesul termodynamic analizat;

$\dot{E}_{ex, consumată}$ – fluxul de energie consumat în procesul termodynamic analizat.

Costurile specifice ale proceselor termodynamice, în vederea realizării unei optimizări termoeconomice (exergoeconomice) considerând scopul realizării acestora au structura:

$$C = C_c + C_{investiții}, \quad (10)$$

$$C_c = C_{c.fluide\ consumabile} + C_{c.expl.} + C_{c.am.}, \quad (11)$$

$$C_{c.fluide\ consumabile} = C_{c.combustibil} + C_{c.ulei} + C_{c.agenți\ termodinamici} + C_{c.alte\ fluide}, \quad (12)$$

$$C_{c,expl} = C_{c,personal\ întreținere} + C_{c,lucrari\ întretinere} + C_{c,taxe}; \quad (13)$$

$$C_{c,am} = C_{c,inicial} + C_{c,rep.cap.} * n_{rep.cap.} - C_{rezidual}; \quad (14)$$

în care: $C_{c,fluide\ consumabile}$ – costurile specifice implicate de consumurile de fluide de lucru (combustibili, ulei, agenți termodinamici, apă etc.); $C_{c,expl}$ – costurile specifice cu salariile personalului de deservire, cu realizarea lucrărilor de menenanță (întreținere), cu acoperirea unor taxe legale; $C_{c,am}$ – costurile specifice pentru amortizarea sistemului termodinamic în care au loc procesele considerate; $C_{investiții}$ – costul specific ce ține cont de investițiile inițiale pentru realizarea sistemului termodinamic ale cărui procese termodinamice trebuie optimizate; $C_{c,inicial}$ – costul specific inițial, al sistemului termodinamic nou dat în exploatare; $C_{c,rep.cap.}$ – costul specific pentru o reparație capitală; $n_{rep.cap.}$ – numărul de reparații capitale; $C_{rezidual}$ – costul specific al sistemului termodinamic scos din exploatare și valorificat.

În relațiile (10)–(13) trebuie să se raporteze costurile la exergile implicate de acțiunile, fluidele folosite etc. Avându-se în vedere obținerea unor profituri maxime în orice activitate practică uneori se consideră drept criteriu de optimizare profitul calculat cu relația:

$$P_r = C_{vânzare} - C; \quad (15)$$

în care: $C_{vânzare}$ – costul specific la vânzarea produsului realizat conform scopului propus de procesele termodinamice optimizate. Dacă $C_{vânzare}$ este impus de piață și poate fi considerat constant, C trebuie să aibă valoarea minima C_{min} pentru a obține $P_{r,max}$ – profitul maxim.

2.1. Algoritmul de călire simulată

Algoritmul se bazează pe analogia dintre procesul călirii aliajelor și rezolvarea problemelor de optimizare combinatorială, în care se caută punctele de optim ale unor funcții de variabile discrete. În cadrul optimizării proceselor termodinamice se consideră ca variabile, funcție de situația studiată, a proiectării sau pentru un sistem termodinamic dat, următoarele: • particularitățile constructive și proprietățile pereților incintei ce constituie frontieră sistemului termodinamic; • natura și proprietățile termodinamice ale fluidelor de lucru; • contactele distincte ale sistemului termodinamic cu exteriorul, contactul termic, contactul mecanic, contactul electric, contactul magnetic, contactele de schimb de substanță cu exteriorul, reacțiile chimice independente din fluidele de lucru etc.; • parametrii termodinamici independenți care determină stările fluidelor de lucru ce suferă procesele termodinamice ce se optimizează.

Problema optimizării combinatoriale se formulează în cazul general prin perechea (S,C) în care S este spațiul configurațiilor și C funcția criteriu de optimizare cu $C:S \rightarrow R$, R-mulțimea numerelor naturale. Mulțimea S este o mulțime numărabilă de configurații. Pentru o configurație optimă i^* rezultă:

$$C(i^*) = \min_{j \in S} C(j), \quad (15)$$

sau

$$\eta_{ex}(i^*) = \max_{j \in S} \eta_{ex}(j), \quad (16)$$

pentru a căror rezolvare se folosește algoritmul de călire simulată, care de fapt este o metodă de calcul probabilistic. Pe cale euristică se construiește rețea neurală artificială care trebuie să evalueze procesele termodinamice cercetate, în care spațiul configurațiilor corespunde mărimilor de intrare independente ce dețină desfășurarea procesului cercetat. Trecerea de la o configurație la alta se face probabilistic folosind distribuția de probabilitate de tip Boltzmann utilizată în fizica statistică sub forma:

$$p = \frac{1}{Z} e^{-\frac{H}{kT}} = e^{-\frac{H-G}{kT}}, \quad Z = e^{-\frac{G}{kT}}, \quad (17)$$

în care: k – constanta lui Boltzmann; H – entalpia; G – entalpia liberă; Z – funcția de partitură.

Instruirea rețelei prin călire simulată constă din: • se prezintă rețelei vectorul de instruire $\vec{x}^i(x_1^i, x_2^i, \dots, x_n^i)$ și se determină mărimile de ieșire și valoarea funcției obiectiv; • se fixează o valoare pentru parametrul de temperatură T_{ip} – temperatură ipotetică (este ipotecă și nu are legătură cu temperatura T din (17)); • se selectează aleator o conexiune (i, k) și w_i^k ponderea acestei conexiuni; se calculează activarea y_k a neuronului k ; • se generează aleator o modificare Δw_i^k a ponderii conexiunii selectate; • se calculează variația ΔC a criteriului de optimizare și apoi probabilitatea de acceptare a modificării Δw_i^k .

$$p_k = e^{-\frac{\Delta C}{T_{ip}}}, \quad (18)$$

• se recalculează activarea neuronului k și valoarea funcției criteriu corespunzătoare modificării ponderii Δw_i^k ; • dacă valoarea funcției criteriu se ameliorează (C scade sau η_{ex} scade) atunci se acceptă schimbarea ponderii, adică $w_i^k := w_i^k + \Delta w_i^k$, iar în caz contrar se trece la pasul următor: • se generează aleator un număr r într-o distribuție uniformă $[0, 1]$ astfel încât pentru $p_k > r$ se determină $w_i^k := w_i^k + \Delta w_i^k$, iar pentru $p_k \leq r$, conexiunea (i, k) păstrează vechea valoare pentru w_{ik} . Algoritmul prezentat este pentru un T_{ip} dat. La pași următori se micșorează temperatura ipotetică de exemplu după legi de formele $T_{ip}(t) = T_{ip,0}/(1+t)$ sau $T_{ip}(t) = T_{ip,0}/(1+\ln t)$ în care t este timpul de calcul conform algoritmului și $T_{ip,0}$ este temperatura ipotetică inițială luată în aplicarea algoritmului. În acest fel algoritmul de călire simulată converge asymptotic spre un minim global al problemei de optimizare combinatorială. Calculele sunt conduse conform topologiei de rețea artificială admisă, care poate fi modificată în funcție de rezultatele obținute privind precizia, convergența etc. și confirmarea experimentală.

2.2. Algoritmi de optimizare pe baza logicii fuzzy

Logica fuzzy are la bază teoria mulțimilor nuanțate (vagi) [20], [27], [28] în care o însușire calitativă a unui obiect capătă valori numerice considerând că există dependențe ale funcției de apartenență: $m_F: X \rightarrow [0,1]$, cu $x \in X$, pentru mulțimea fuzzy în X ca rezultat al aplicației $F: X \rightarrow [0,1]$. Funcția de apartenență $m_F(x)$ se poate accepta [23] triunghiulară, trapezoidală, parabolică, de tip armonic, de tip „clopot”, de tip saturare etc. așa încât mărimile precizate vag capătă valori numerice, după importanța lor în formularea problemei, importanță acordată și având un pronunțat caracter „uman”. Instruirea rețelei neuronale artificiale capătă un caracter nuanțat prin mărimile nuanțate introduse și se realizează după metodele obișnuite, cu particularități privind mulțimile mărimilor de ieșire, separarea acestora și evaluarea distanțelor dintre acestea. Pentru studiul optimizării proceselor termodinamice se pot utiliza diverse tipuri de rețele neuronale artificiale nuanțate [9], [17]–[19], la care se aplică algoritmi specifici de învățare și se poate implementa algoritmul de călare simulată arătat mai sus pentru găsirea optimului absolut în mulțimea posibilă a punctelor de optim relative (locale). Se propune utilizarea algoritmului generalizat al Perceptronului nuanțat, [23], numit algoritmul Gallant nuanțat.

3. CONCLUZII

Optimizarea proceselor termodinamice complexe actuale, întâlnite în tehnică și în biologie, nu pot fi rezolvate prin metodele clasice bazate pe modele deterministe și/sau stocastice fără a face apel la metodele de inteligență artificială. În acest fel se pot considera foarte mulți parametri independenți care pot fi cuantificați, în cazul cunoașterii lor calitative, așa cum sunt parametrii de calitate implicați de procese tehnologice de fabricație, montare, reparare, calitatea materialelor și a fluidelor folosite etc., cu ajutorul teoriei mulțimilor fuzzy și a logicii multivaleente fuzzy. Utilizarea teoriei rețelelor neuronale conduce la rezultate mai exacte prin folosirea mai multor parametri independenți și a unor algoritmi mai simpli, ce necesită eforturi de calcul mai mici. Modelul de rețea neuronală a Perceptronului [9], și algoritmii propuși, se potrivesc sistemelor termodinamice actuale întâlnite în funcționarea mașinilor și echipamentelor termice de orice tip atât pentru optimizarea acestora cât și pentru diagnoza stării lor tehnice, cu implicații în minimizarea cheltuielilor pentru executarea lucrărilor de menenanță. Algoritmii arătați mai sus pot fi implementați folosind programul Matlab [23]. Cercetările teoretice pot fi ajutate de cercetările experimentale bazate pe măsurătorile obținute cu aparatura Disa Electronic, Brüel & Kjær, fabricate în Danemarca și/sau aparatura National Instruments fabricată în SUA [29].

BIBLIOGRAFIE

- [1] Baehr H.D., *Thermodynamik*, Springer Verlag, Berlin, Heidelberg, New York, 1966.
- [2] Bejan A., *Advanced Engineering Thermodynamics*, A Wiley-Interscience Publication John Wiley & Sons, New York, Chichester, Brisbane, Toronto, Singapore, 1988.
- [3] Bazarov I.P., *Termodinamica*, Editura Tehnică, București, 1962.
- [4] Belea C., *Teoria sistemelor*, vol. II, Editura Didactică și Pedagogică, București, 1985.
- [5] Bendat, J.S., Piersol, A.G., *Measurement and Analyses of Random Data*, John Wiley, New York, 1966.
- [6] Cox, D.R., Miler, H.D., *The Theory of Stochastic Processes*, London, 1967.
- [7] Dincă G., *Metode variaționale și aplicații*, Editura Tehnică, București, 1980.
- [8] Dragoș L., *Principiile mecanicii mediilor continue*, Editura Tehnică, București, 1986.
- [9] Dumitrescu, D., Costin, H., *Neural Network. Theory and Applications*, Teora Publishers, Bucharest, 1996.
- [10] Dumitru Gh., *Modeling of the Thermodynamic Processes on the Base of Neural Network Theory*, Xth National Conference of Thermotechnics, “Lucian Blaga” University of Sibiu, May, 2000.
- [11] Dumitru Gh., *Optimization of the Naval Energetic Plants on the Base of Neural Network Theory*, The Annals of the University „Dunărea de Jos“ of Galatz, Fascicle IV, Refrigerating Technique, Internal Combustion Engines, Boilers and Turbines, Year XV, 1998-1999, pag. 5-8.
- [12] Gabos Z., *Termodinamică fenomenologică*, Editura Academiei Române, București, 1959.
- [13] Guikhmann I.K., Skovokhod A., *Introduction à la théorie des processus aléatoires*, Edition Mir, Moscou, 1990.
- [14] Ionescu V., *Teoria sistemelor*, vol. I, Editura Didactică și Pedagogică, București, 1985.
- [15] Iosifescu M., Mihoc Gh., Theodorescu R., *Teoria probabilităților și statistică matematică*, Editura Tehnică, București, 1966.
- [16] Karapetiantz M., *Thermodynamique chimique*, Edition Mir de Moscou, 1978.
- [17] Kasko, B., *Neural Networks and Fuzzy Systems*, Prentice Hall, Englewood Cliffs, 1992.
- [18] Moren, A. J., *Handbook of Neural Computing. Applications*, Academic Press, 1990.
- [19] Müller, B., Reinhardt, J., *Neural Networks*, Springer Verlag, 1990.
- [20] Negoită, C.V., Rădescu, D.A., *Mulțimile Fuzzy și aplicațiile lor*, Editura Tehnică, București, 1983.
- [21] Săcvă V.V., *Sisteme termodinamice complexe*, Editura Științifică și Enciclopedică, București, 1982.
- [22] Sedov L., *Mecanique des milieux continus*, Edition Mir de Moscou, 1975.
- [23] Sofron, E., Bizon, N., Ionita, S., Raducu, R., *Fuzzy Control Systems. Modeling and Computer Aided Design*. All Educational Publishers, Bucharest, 1998.
- [24] Spataru, Al., *Transmission Theory of Information*, Didactic and Pedagogic Publishers, Bucharest, 1979.
- [25] Stanomir, D., Stănișilă, O., *Metode matematice în teoria semnalelor*, Editura Tehnică, București, 1980.
- [26] Todorean, G., Costei, M., Giurgiu, M., *Artificial Neural Networks*, Blue Home Publishers, Cluj-Napoca, 1995.
- [27] Zadeh, L.A., *Fuzzy Sets and Systems*, Proc. of the Symposium on System Theory, Polytechnical Institut of Brooklyn, New York, 1965.
- [28] Zimmermann, H.J., *Fuzzy Set Theory and its Applications*, Boston, 1991.
- [29] ** LabVIEW, Function on VI. Reference Manual. National Instruments, Austin, Texas, USA, 1998.