

Sistem de recunoaștere a defectelor în materialele textile

Dragoș Cătălin Barbu

ICI București

Mareșal Averescu 8-10, București

dbarbu@ici.ro

Dragoș Nicolae Nicolau

ICI București

Mareșal Averescu, 8-10, București

dragos@ici.ro

REZUMAT

În producția de țesături, pentru asigurarea calității, detectarea defectelor este un pas vital. Această lucrare prezintă un sistem de detectare a defectelor în țesături în timp real care necesită algoritmi eficienți și puternici de detectare a defectelor. Pe baza caracteristicilor structurii țesăturilor, folosim modelele local binare (*Local Binary Patterns* – LBP) pentru a detecta defectele în țesături. Datorită caracteristicilor subtile ale defectelor, inspecția defectelor din țesături este deosebit de dificilă dar și datorită variațiilor în textura țesăturii și modificărilor factorilor de mediu (de ex.: iluminare, zgomot, etc.). Implementarea online a algoritmilor a arătat că poate fi implementat cu resurse disponibile în mod obișnuit și poate fi adaptată pentru aplicații industriale.

Cuvinte cheie

Clasificare, defecte, textură.

Clasificare ACM

H4.Information systems applications, H4.2 Types of Systems: Logistics; H4.m: Miscellaneous

INTRODUCERE

Toate industriile textile au ca scop producerea de produse competitive. Îmbunătățirea competitivității depinde în primul rând de productivitate și de calitatea materialelor produse de fiecare industrie. În sectorul textil a existat o creștere a pierderilor cauzate de țesăturile defectuoase. Reducerea costului în producția și procesul de inspecție este, de asemenea, un obiectiv important pentru fabricanții de textile. În prezent procesul de inspecție al calității este efectuat manual de către experți. Țesăturile caracteristice sunt de 1-3 m lățime și sunt rulate cu o viteză între 20 și 200 m/min. Experți nu pot detecta mai mult de 60% din totalul defectelor dacă țesătura este rulată cu o viteză mai mare de 30m/min sau dacă au o lățime mai mare de 2 m [4]. Ca orice alt proces de inspecție, este dependentă de experiența muncitorilor de până acum. Dezvoltarea unui sistem online flexibil, eficient, de încredere și integrat pentru aplicații industriale este o problemă esențială în procesul de control al calității pentru fabricanții de textile. În particular, dacă există un defect, se reduce prețul țesăturii între 45%-65% [10]. Pentru a crește calitatea în general, omogenitatea țesăturii și coeficientul de siguranță (trăinicia), un sistem vizual de inspecție este necesar pentru o mai bună productivitate.

În sectoarele textile, sunt disponibile diferite tipuri de defecte, de ex.: gaură, zgârietură, întindere, fir tras, pată murdară, scamă, punct de rupere, decolorare, etc.; în cazul

în care nu sunt detectate corespunzător, aceste anomalii pot afecta procesul de producție. Astfel, automatizarea sarcinii de inspecție vizuală poate crește eficiența de pe linia de producție și să îmbunătățească, de asemenea, și calitatea produsului.

Majoritatea sistemelor automatizate de inspecție a țesăturilor nu sunt în timp real și au o viteză de detectare de până la 100m/min. Un punct important al acestor sisteme este că fiecare dintre ele pot detecta doar tipuri specifice de defecte.

ANALIZA LITERATURII DE SPECIALITATE

Au existat multe încercări de a rezolva aceste probleme în ultimele 3 decenii. Încercările s-au bazat pe trei abordări diferite: statistic, spectral și bazate pe modele. În abordarea statistică, caracteristicile de textură a nivelurilor gri extrase de către o matrice de co-apariție [12], autocorelarea sub-imaginilor [13], și transformări Karhunen-Loeve (KL) au fost folosite pentru detectarea defectelor țesăturilor. Bodnarova et al. [1] au folosit funcții de normalizare cu corelație încrucișată pentru detectarea defectelor în materiale. Cohen et al. [5] folosește un model de câmp aleator Markov (MRF) pentru inspecția defectelor din țesături. Chen and Jain [3] folosesc o abordare structurală pentru detectarea defectelor în imaginile texturate. Există de altfel și multe abordări spectrale pentru detectarea defectelor din țesături. De exemplu, Kumar and Pang [6] propun o metodă pentru detectarea defectelor folosind filtre Gabor care necesită un număr mare de calcule. Ei au dezvoltat de asemenea folosind doar partea imaginară a filtrelor Gabor. Chan and Pang [2] oferă o metodă pentru detectarea defectelor în țesăturile textile folosind analiza Fourier. Deoarece bazele Fourier sunt de lungime infinită, contribuția fiecărei componente spectrale este dificil de cuantificat. Astfel, analiza Fourier nu este adecvată pentru detectarea defectelor locale. Kumar and Pang[7] au dezvoltat o metodă pentru detectarea defectelor în țesăturile textile folosind filtre optimizate.

Ngan et al. [8] au folosit o metodă bazată pe wavelet-uri pentru detectarea defectelor pe țesături cu model. O țesătură cu model este definită prin unități de modele repetitive în planul ei. Sub clasa țesăturilor cu model există multe categorii.

Cercetările din acest sector pot fi împărțite în două categorii diferite. În prima categorie, toate încercările sunt pentru a crește raza de defecte care pot fi detectate, în timp ce acestea necesită un număr mare de calcule. Referințele [2,6,7] aparțin acestei categorii. În cea de-a doua, creșterea vitezei de detecție este ținta, în timp ce o raza mică de

defecte pot fi detectate. Referințele [1,3,5,12,13] aparțin celei de-a doua categorii.

METODĂ

Vom prezenta o metodă simplă și directă pentru detectarea iregularităților în textura țesăturilor, care pot detecta o rază mare de defecte. În această metodă, se folosesc modele locale binare (LBPs). Ar trebui știut că LBP este folosit pentru clasificarea texturilor [9] dar în această lucrare este folosit pentru detectarea defectelor texturale din țesături. Această metodă este bazată pe recunoașterea acelor caracteristici LBP care sunt proprietăți fundamentale a texturilor imaginilor locale și histograma acestora este dovedită ca fiind o caracteristică foarte puternică pentru texturi [9]. LBP este un operator de textură de discriminare înaltă. Înregistrează aparițiile diferitelor modele în vecinătatea fiecărui pixel în histograma P-dimensionale. Astfel, această metodă este folosită pentru detectarea defectelor texturale din țesături. Metoda propusă este simplă, multi-rezoluțională, și invariantă la scara gri (gray scale).

Prin această metodă, se ia în considerare o vecinătate a imaginii și nivelul de gri al pixelului din centru este comparat cu nivelurile de gri ale celorlalți pixeli din vecinătate. De obicei, vecinătatea este în formă circulară și estimarea valorilor de gri ale pixelilor care nu cad în centru se face prin interpolare. Figura 1 ilustrează mulțimile vecinătăților circular simetrice pentru diferite raze, R, și număr diferit de vecini, P.




Figura 1. Mulțimea vecinătăților circular simetrice

În forma de bază a acestei metode operatorul LBP într-o vecinătate a imaginii se definește astfel [9]:

$$LBP_{P,R} = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i, \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

În (1), valoarea de gri a pixelului central este g_c și valoarea gri al celui de-al i-lea vecin este g_i . Conform acestei definiții, se observă că valoarea finală este număr pe P biți cu 2^P valori distincte. Pe de altă parte, valoarea finală este dependentă de etichetarea vecinilor. Când imaginea este rotită, deoarece vecinătatea este considerată în formă circulară, vecinii se vor muta în mod corespunzător de-a lungul perimetrului cercului. Pentru ca algoritmul să fie invariant la rotație și pentru a atribui o valoare unică pentru fiecare vecinătate, valoarea finală a operatorului LBP este rotită și se selectează valoarea minimă:

$$LBP_{P,R}^i = \min\{ROR(LBP_{P,R}, i) \mid i = 0, 1, \dots, P - 1\} \quad (2)$$

În (2), un număr pe P-biți este rotit de i ori și este selectată valoarea minimă a valorilor rezultate pentru i între 0 și P-1. ROR este prescurtarea de la rotație la dreapta. În versiunea modificată a LBP [9], se definește mai întâi o măsură U , ca numărul tranzițiilor spațiale între 1 și 0 din model. Apoi modelele care au măsura de uniformitate mai mică decât U_T se definesc ca modele uniforme. Astfel forma modificată a LBP este definită astfel:

$$LBP_{P,R}^{riuT} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c), & \text{if } U(LBP_{P,R}) \leq U_T \\ P + 1, & \text{altfel} \end{cases} \quad (3)$$

unde $U(LBP_{P,R}i)$ este măsura de 'uniformitate' a modelului.

$$U(LBP_{P,R}ri) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|$$

În Figura 2 se exemplifică câteva modele uniforme și modele neuniforme.




Figura 2. Exemple de modele uniforme și neuniforme

Ecuția (3) arată că LBP modificat atribuie valori între 0 și P pentru vecinătăți uniforme și eticheta P+1 pentru cele neuniforme. După aplicarea acestui operator asupra imaginii, probabilitatea de a întâlni o etichetă specifică poate fi aproximată prin raportul dintre numărul de vecinătăți care au aceea etichetă și numărul total al vecinătăților. Astfel, la sfârșitul acestui proces vor fi calculate P+2 probabilități. Aceste probabilități vor fi utilizate ca și caracteristici pentru clasificare. Pentru clasificare se folosește raportul logaritmice al probabilităților. O probă supusă unui test aparține clasei K dacă probabilitățile calculate minimizează următorul raport:

$$L(S, K) = \sum_{i=0}^{P+1} \log \left(\frac{S_i}{M_{iK}} \right). \quad (4)$$

În ecuația (4), M_{iK} este probabilitatea de a întâlni eticheta i în modelele clasei K, și S_i este probabilitatea de a întâlni eticheta i găsită din eșantionul testat. Conform ecuației (3), orice schimbare monotonă în valorile de gri nu modifică modelul și metoda este invariantă față de schimbările scalei gri.

Algoritmul de recunoaștere a defectelor

Atât în versiunea de bază a operatorului LBP cât și în cea modificată, selectarea vecinătății în formă circulară este folosită pentru ca algoritmul să fie invariant la rotație. Nu mai este necesară selectarea vecinătății circular întrucât în timpul procesului de inspecție rotația ruloarelor textile poate fi evitată. Pe de altă parte, calcularea luminozității

prin interpolare în vecinătăți circulare necesită mult timp. Prin urmare, în această metodă, se ia în considerare o vecinătate pătratică. În acest caz notația LBP este redenumită de la $LBP_{P,R}$ la LBP_{P,w_m} în care dimensiunea ferestrei pentru care se aplică operatorul LBP este de $w_m \times w_m$ pixeli. Figura 3 ilustrează vecinătățile pătratice și cum se aplică operatorul LBP. Folosind operatorul LBP se asignează o etichetă de la 0 la P+1 pentru fiecare vecinătate a imaginii. Aceste etichete reflectă relația dintre un pixel și vecinii săi. Ca și caracteristică a metodei de detectare a defectelor folosim probabilitatea de a întruni aceste etichete. Rezultatele experimentelor [11] arată că în cazul în care probabilitatea de a întâlni o etichetă P+1, care este atribuită zonelor neuniforme, este mică (mai puțin de 1%) aceste caracteristici pot clasifica corect textura, altfel, diferite modele din țesătură vor lua aceeași etichetă (P+1) și nu pot fi clasificate.




Figura 3. Vecinătăți pătratice și operatorul LBP

Din rezultate [11], dacă în definiția operatorului LBP valoarea lui U_T este egală cu P/4, doar o porțiune neglijabilă a modelelor din textură iau ca valori etichete P+1. Rezultatul algoritmului va fi o imagine binară care este definită ca model de defect. Pixeli albi din modelul de defect reprezintă zonele fără defecte din țesătură și pixeli negri reprezintă zonele cu defecte. Dimensiunea modelului cu defect este aceeași cu dimensiunea imaginii de intrare.

Detectarea defectelor în țesătură

În etapa de antrenare, pentru detectarea defectelor în țesături fără țipare, operatorul LBP se aplică asupra întregii imaginii fără defecte și se calculează vectorul caracteristic M. Fiecare element din vector este probabilitatea întrunirii etichetelor de la 0 la P+1 în imaginea fără defecte. Dacă numărul de puncte din operatorul LBP (numărul de pixeli din vecinătate) este P, vectorul caracteristic care va fi notat cu M va fi de dimensiune P+2. După calcularea vectorului M, imaginea cu țesătura fără defecte este împărțită în ferestre care nu se suprapun de dimensiune $W_d \times W_d$ care le denumim ferestre de detecție. Se aplică operatorul LBP pentru fiecare din aceste ferestre. Fereastra pentru aplicarea operatorului LBP o denumim mască LBP. Fiecare element al vectorului de caracteristici calculat pentru o fereastră este probabilitatea de a întâlni o etichetă specifică în acea fereastră.

Pentru a estima corect aceste probabilități, numărul operatorilor aplicați fiecărei ferestre de detecție ar trebui să fie suficient de mare (ca regula de bază, cel puțin 100 de operatori pe fiecare fereastră). Dacă dimensiunea ferestrei de detecție este $W_d \times W_d$ și dimensiunea măștii LBP este $w_m \times w_m$ ($W_d \gg w_m$), atunci numărul de operatori din fiecare fereastră va fi $(W_d - w_m + 1)^2$. Prin

urmare, în cazul în care numărul minim de operatori aplicați este 100, atunci $W_d \geq 9 + w_m$.

Trebuie remarcat faptul că vectorul de caracteristici extras de către operatorul LBP poate descrie textura țesăturii corect dacă texturile care apar în ferestrele de detecție sunt similare cu texturile țesături. Așadar, dimensiunea ferestrei de detecție ($W_d \times W_d$) creată pe imagine ar trebui să fie mai mare decât dimensiunea unității repetitive de pe textura țesăturii. Cu toate acestea, în țesături fără țipare, singura condiție asupra dimensiunii ferestrei este $W_d \geq 9 + w_m$.

Capacitatea algoritmului de a detecta defecte mici și rezoluția modelului de defect scad odată cu creșterea dimensiunii ferestrei de detecție. Prin aplicarea operatorului LBP pentru fiecare din aceste ferestre, se calculează vectorul S_K care este de dimensiune P+2. Raportul logaritm al vecinătăților pentru fiecare din aceste ferestre se calculează astfel:

$$L_K(S_K, M) = \sum_{i=0}^{P+1} S_{ik} \log \left(\frac{S_{ik}}{M_i} \right), k = 1, 2, \dots, N. \quad (5)$$

În ecuația (5), N reprezintă numărul de ferestre de detecție. Deoarece minimizarea raportului logaritm al vecinătăților ne arată similaritatea față de o clasă specifică, valoarea maximă dintre aceste rapoarte va fi folosită ca și prag pentru ferestrele fără defecte astfel:

$$T = \text{Max}(L_K), k = 1, 2, \dots, N. \quad (6)$$

După calcularea vectorului de caracteristici M și a pragului T, în etapa de detectare, imaginea testată este împărțită în ferestre de detecție și se calculează raportul logaritm al vecinătăților pentru fiecare din aceste ferestre. Dacă raportul logaritm al vecinătăților depășește pragul, fereastra relevantă aparține zonei cu defect a țesăturii. Pentru a crește capacitatea de detecție a algoritmului, o zonă mare a ferestrei de detecție ar trebui să fie ocupată de defect. Așadar, în etapa de detectare, imaginea este împărțită în ferestre care se suprapun. Conform rezultatelor simulării, dacă pasul de suprapunere a ferestrei de detecție este $W_d/2$, algoritmul are o putere de detecție corespunzătoare. Prin creșterea pasului suprapunerii se va descrește viteza de detecție.

REZULTATE EXPERIMENTALE

S-a utilizat o aplicație Windows care funcționează pe baza a 5 fire de execuție: capturare imagine cu ajutorul camerei web, memorare imagine capturată, detectare defecte, clasificare defecte, afișare în listă; prezența acestor fire conferă utilizatorului posibilitatea de a interacționa cu aplicația (inclusiv cea de a întrerupe / relua după voce operații de alegere material, detectare defecte etc.) în condițiile în care toate acțiunile de mai sus sunt de durată.

La pornire, aplicația detectează toate camerele web și memorează rezoluțiile fiecărei camere de captură. În sub-fereastra stângă va fi afișată imaginea alb-negru a capturii curent analizate: cu alb este marcată zona de țesătură corectă, cu negru sunt marcate defectele; în sub-fereastra dreaptă este prezentă lista care afișează numele, dimensiunile și amplasarea defectelor în șarja textilă.

Imaginea reală de captură este afișată în timp real în fereastra de previzualizare.




Figura 4. Afișarea defectelor detectate pe captura curentă

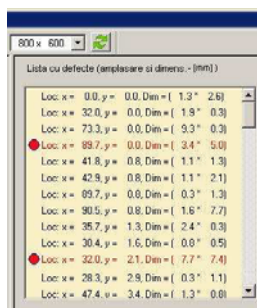


Figura 5. Subfereastra de afișare a defectelor clasificate

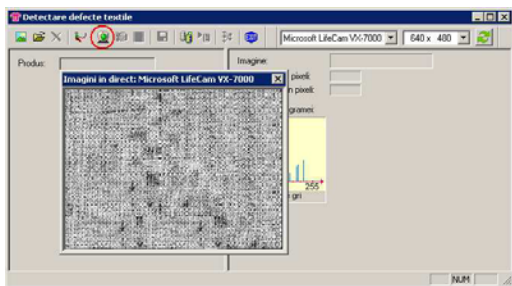


Figura 6. Fereastra de previzualizare

Fereastra adițională de previzualizare oferă posibilitatea de a observa în timp real „filmarea” eșantionului textil în timpul derulării; fereastra se poate amplasa și redimensiona după voie, caz în care își păstrează intact raportul dimensiunilor. S-au realizat teste pe 20 de eșantioane de produse textile, pe baza a 12 tipuri de defecte considerate a fi cel mai des întâlnite. În tabelul de mai jos prezentăm rata de succes a detectării cu operatorul LBP a primelor 6 cele mai frecvente defecte, dintre cele 12 sus-amintite: (a) fir dublu, (b) fir absent, (c) ruptură, (d) zonă descusută, (e) fir străin și (f) noduri.

Tabelul 1. Rata de detecție

Vecini, raza	Tip defect					
	a	b	c	d	e	f
8,3	97	85	95	92	94	95
16,5	98	90	93	90	94	93
24,7	95	ND	93	90	93	90
8,3+16,5	98	98	98	95	97	97

Metoda prezintă are o rată de detecție acceptabilă (mai mult de 90 %) în aproape toate tipurile de defecte testate.

CONCLUZII

Această metodă este utilă pentru industria textilă în procesele de inspecție, identificare și localizare a defectelor în produsele textile. Chiar dacă modelul de defect este de rezoluție mică, modelul de defect generat de această metodă este compatibil cu o gamă largă de defecte. Metoda poate fi folosită și pentru detectarea defectelor în produse care au texturi regulate și periodice, cum ar fi lemn sau plastic.

CONFIRMARE

Această lucrare a fost sprijinită din proiectul de cercetare PN2 C71-142/2008.

REFERINȚE

1. A. Bodnarova, M. Bennamoun, and K. Kubik, “Defect detection in textile materials based on aspects of the HVS,” in *Proceedings of IEEE International Conference on Systems, (SMC '98)*, vol. 5, pp. 4423–4428, San Diego, Calif, USA, October 1998.
2. C.-H. Chan and G. K. H. Pang, “Fabric defect detection by Fourier analysis,” *IEEE Transactions on Industry Applications*, vol.36(5), pp. 1267–1276, 2000.
3. J. Chen and A. K. Jain, “A structural approach to identify defects in textured images,” in *Proceedings of IEEE International Conference on Systems, (SMC '88)*, vol. 1, pp. 29–32, Beijing, China, August 1988.
4. C.-S. Cho, B.-M. Chung, and M.-J. Park, - “Development of real-time vision-based fabric inspection system”, *IEEE Transactions on Industrial Electronics*, vol. 52, no. 4, pp. 1073–1079, 2005.
5. F. S. Cohen, Z. Fan, and S. Attali, “Automated inspection of textile fabrics using textural models,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, no. 8, pp. 803–808, 1991.
6. A. Kumar and G. K. H. Pang, “Defect detection in textured materials using Gabor filters,” *IEEE Transactions on Industry Applications*, vol. 38, no. 2, pp. 425–440, 2002.
7. A. Kumar and G. K. H. Pang, “Defect detection in textured materials using optimized filters”, *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, vol. 32, no. 5, pp. 553–570, 2002.
8. H. Y. T. Ngan, G. K. H. Pang, S. P. Yung, and M. K. Ng, “Defect detection on patterned jacquard fabric”, in *Proceedings of the 32nd Applied Imagery Pattern Recognition Workshop(AIPR '03)*, pp. 163–168, Washington, DC, USA, October 2003.
9. T. Ojala, M. Pietik`ainen, and T. M`aenp`a`a, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
10. R. Stojanovic, P. Mitropulos, C. Koulamas, Y. A. Karayiannis, S. Koubias, and G. Papadopoulos, “Real-time Vision based System for Textile Fabric Inspection”, *Real-Time Imaging*, vol. 7, no. 6, 2001, pp. 507–518.
11. F. Tajeripour, E. Kabir, A. Sheikhi, „Fabric defect detection using modified local binary patterns”, *Eurasip Journal on Advanced in Signal Processing*, vol. 2008
12. I.-S. Tsai, C.-H. Lin, and J.-J. Lin, “Applying an artificial neural network to pattern recognition in fabric defects”, *Textile Research Journal*, vol. 65, no. 3, pp. 123–130, 1995.
13. E. J. Wood, “Applying Fourier and associated transforms to pattern characterization in textiles”, *Textile Research Journal*, vol. 60(4), pp. 212–220, 1990