



RO 133583 A2

(51) Int.Cl.

G06K 9/00 (2006.01);
G06K 9/46 (2006.01);
G06T 7/20 (2006.01);
G06T 7/269 (2017.01);
G06N 3/02 (2006.01)

(12)

CERERE DE BREVET DE INVENTIE

(21) Nr. cerere: a 2018 00129

(22) Data de depozit: 27/02/2018

(41) Data publicării cererii:
30/08/2019 BOPI nr. 8/2019

(71) Solicitant:

• SECURIFAI S.R.L., BD.MIRCEA VODĂ
NR.24, ET.3, CAMERA 12, SECTOR 3,
BUCHUREŞTI, B, RO

(72) Inventatorii:

• IONESCU RADU TUDOR, STR.OVIDIU
NR.15, BL.LC5, AP.51, GALAȚI, GL, RO;

• SMEUREANU SORINA,
STR.CALEA LUI TRAIAN NR.144, BL.4,
SC.F, AP.8, RÂMNICU VÂLCEA, VL, RO;
• ALEXE DUMITRU BOGDAN,
STR.SERGEANT TACHE GHEORGHE NR.6,
BL.B43, AP.4, SECTOR 4, BUCUREŞTI, B,
RO;
• POPESCU MARIUS NICOLAE,
BD.CONSTANTIN BRÂNCOVEANU NR.8,
BL.B2, SC.1, AP.17, BUCUREŞTI, B, RO

(54) METODĂ ȘI ALGORITM BAZAT PE GRADIENTI DE MIȘCARE ȘI REȚELE NEURONALE CONVOLUTIONALE PENTRU DETECTAREA ȘI LOCALIZAREA AUTOMATĂ A EVENIMENTELOR ANORMALE DIN VIDEO

(57) Rezumat:

Invenția se referă la o metodă și la un algoritm pentru detectarea și localizarea automată a evenimentelor anormale dintr-o înregistrare video. Algoritmul conform invenției se bazează atât pe trăsături ce reprezintă mișcarea din înregistrarea video, cât și pe trăsături ce reprezintă înfățișarea sau postura obiectelor sau a persoanelor și cuprinde, pentru reprezentarea mișcării, extragerea gradientilor de mișcare 3D și acumularea lor în regiuni de dimensiune fixă, numite cubozi spațio-temporali din care se păstrează, pentru procesări ulterioare, doar regiunile pentru care magnitudinea gradientilor depășește un anumit prag, iar pentru reprezentarea obiectelor și a posturii lor, se folosește o rețea neuronală convolutională antrenată pe un set de date ImageNet pentru problema recunoașterii obiectelor din imagini, trăsăturile extrase din rețeaua convolutională fiind combinate apoi cu gradientii de mișcare într-un vector de trăsături ce reprezintă o subregiune spațio-temporală din înregistrarea video. Antrenarea algoritmului se realizează astfel: într-o primă etapă se folosește un algoritm de clusterizare pentru a grupa vectorii de trăsături în funcție de similaritate, se utilizează un prag prestabilit pentru a elimina grupurile cu mai puține elemente, iar pentru fiecare grup rămas se antrenează câte un clasificator SVM (Support Vector Machines) adaptat pentru o singură clasă, într-o etapă de testare se aplică clasificatorii pe cubozi rezultați din fișierele video de testare și, pentru fiecare exemplu, se consideră scorul de anomalie ca fiind maximul dintre scorurile date de clasificatorii SVM; în final se obțin scorurile la nivel de cadru, considerând scorul maxim al

cuboizilor ce aparțin unui cadru video, după care scorurile astfel obținute sunt netezite aplicând un filtru Gaussian pe dimensiunea temporală, iar pentru detectarea cadrelor ce conțin evenimente anormale se aplică un prag prestabilit peste scorurile calculate la nivel de cadru.

Revendicări: 1

Figuri: 9




Fig. 1

Cu începere de la data publicării cererii de brevet, cererea asigură, în mod provizoriu, solicitantului, protecția conferită potrivit dispozitivilor art.32 din Legea nr.64/1991, cu excepția cazurilor în care cererea de brevet de inventie a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de inventie este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).




RO 133583 A2

Metodă și algoritm bazat pe gradienți de mișcare și rețele neuronale convoluționale pentru detectarea și localizarea automată a evenimentelor anormale din video

Inventatori:

Radu Tudor Ionescu
 Sorina Smeureanu
 Bogdan Alexe
 Marius Nicolae Popescu



Aplicant:

SecurifAI
 Bd. Mircea Vodă Nr. 24
 București, Romania

Rezumat:

Algoritmul propus pentru detectarea și localizarea evenimentelor anormale din video se bazează atât pe trăsături ce reprezintă mișcarea din video cât și pe trăsături ce reprezintă înfățișarea sau postura obiectelor sau a persoanelor. Pentru reprezentarea mișcării, extragem gradienți de mișcare 3D pe care îi acumulăm în regiuni de dimensiune fixă. Aceste regiuni se numesc *cuboizi spațio-temporali*. Pentru procesarea ulterioară, păstrăm doar regiunile pentru care magnitudinea gradienților depășește un anumit prag. Pentru reprezentarea obiectelor și a posturii lor folosim o rețea neuronală convoluțională antrenată pe setul de date ImageNet pentru problema recunoașterii obiectelor din imagini. Trăsăturile extrase din rețeaua convoluțională sunt combinate cu gradienții de mișcare într-un vector de trăsături care reprezintă o sub-regiune spațio-temporală din video. În prima etapă de antrenare, folosim algoritmul de clusterizare k-means pentru a grupa vectorii de trăsături în funcție de similaritate. Utilizăm un prag prestabilit pentru a elimina grupurile cu mai puține elemente. Pentru fiecare grup rămas, antrenăm câte un clasificator SVM (Support Vector Machines) adaptat pentru o singură clasă. În faza de testare, clasificatorii se aplică pe cuboizi rezultați din fișierele video de test. Pentru fiecare exemplu considerăm scorul de anomalie ca fiind maximul dintre scorurile întoarse de clasificatorii SVM. În final, obținem scorurile la nivel de frame (cadru) considerând scorul maxim dintre cuboizii ce aparțin unui cadru din video. Scorurile astfel obținute sunt netezite aplicând un filtru Gaussian pe dimensiunea temporală. Pentru detectarea și marcarea cadrelor ce conțin evenimentelor anormale, se aplică un prag prestabilit peste scorurile calculate la nivel de cadru.

1. Introducere în domeniu

Detectarea automată a evenimentelor anormale din video este o problemă studiată în domeniul vederii artificiale, existând un număr relativ restrâns de lucrări științifice [1, 2, 4, 5, 6, 7, 8, 9, 12, 13, 14, 15, 16, 18, 21, 22, 23, 24, 25] care au abordat această problemă. Așa cum este definit în literatura de specialitate [6, 8], un *eveniment anormal* poate fi orice eveniment care se întâmplă mai rar decât evenimentele familiare, adică cele care se întâmplă în mod frecvent. Această definiție implică faptul că marcarea unui eveniment ca fiind anormal depinde


de context. De exemplu, un autovehicul care circulă pe stradă cu 50 de km/h în mod regulamentar este considerat un eveniment normal, în schimb un autovehicul care intră într-o zonă pietonală cu aceeași viteză lovind pietonii din jur este considerat eveniment anormal. Deși în ambele situații mașina circulă cu aceeași viteză, diferența între marcarea evenimentului ca normal sau ca anormal este dată de context, adică de ceea ce se întâmplă în jur și de efectele pe care le produce evenimentul. Deoarece definiția unui eveniment anormal depinde de contextul în care se întâmplă evenimentul respectiv, problemă detectării evenimentelor anormale este una generică. Printre situațiile care se încadrează în problema detectării evenimentelor anormale din video se numără și:

- a) Incendii și explozii, precum și efecte ale acestora care sunt surprinse cu camera de luat vederi. Printre exemplele de efecte produse de incendii sau explozii, care pot fi considerate evenimente anormale se numără: persoane care aleargă pentru a scăpa de incendiu, obiecte aruncate în urma sufului exploziei, etc.
- b) Accidente rutiere, participanți la trafic care execută manevre interzise, cum ar fi: pietoni care traversează prin loc nepermis, mașini care întorc pe banda dublă continuă, mașini care circulă pe o stradă cu sens interzis, etc.
- c) Persoane care participă la comiterea unei infracțiuni (jaf cu sau fără armă, bătaie, altercație, pătrundere frauduloasă într-o incintă sau loc nepermis, etc.) având un comportament agresiv, agitat, sau pur și simplu diferit de cel al unei persoane cu comportament normal.
- d) Fenomene naturale extreme (fulgere, vânt puternic), precum și efecte ale acestora care sunt surprinse cu camera de luat vederi. Printre exemplele de efecte produse de fenomenele naturale extreme, care reprezintă evenimente anormale pot fi: obiecte luate de vânt, crengi rupte, copaci smulși din rădăcină, etc.

În toate situațiile enumerate mai sus, se poate utiliza un algoritm pentru detectarea evenimentelor anormale din video, cu scopul de a detecta automat situațiile periculoase care pot aduce pierderi de vieți omenești, pagube materiale sau încălcări ale legii. Totuși, lista de evenimente nu este una completă, fiind de fapt imposibil de realizat o listă exhaustivă de situații în care se poate aplica un algoritm pentru detectarea evenimentelor anormale din video. Din acest motiv, o alternativă viabilă și des folosită în practică [1, 2, 4, 5, 7, 9, 12, 13, 14, 15, 16, 18, 21, 22, 23, 24, 25] constă în construirea unui algoritm capabil să modeleze evenimentele normale din video în baza unei etape de antrenare, folosind tehnici din vederea artificială și învățarea automată. Antrenarea algoritmului presupune accesul la unul sau mai multe fișiere video care conțin doar evenimente normale dintr-o anumită locație supravegheată cu camera de luat vederi. Deoarece evenimentele normale se întâmplă în mod frecvent, colectarea fișierelor video pentru antrenarea algoritmului implică un efort minim de timp.

2. Metode și tehnici similare


În mod uzual, problema detectării evenimentelor anormale din video este formalizată ca o problemă de detectare a valorilor aberante [2, 4, 5, 7, 9, 12, 13, 14, 15, 16, 21, 22, 23, 24, 25], în care abordarea este în general bazată pe învățarea unui model de normalitate din date de antrenare conținând doar evenimente normale, și pe considerarea valorilor aberante ca fiind evenimente anormale. Unele abordări pentru detectarea evenimentelor anormale [4, 5, 7, 13, 16, 21] se bazează pe construirea unui dicționar de evenimente normale și pe etichetarea evenimentelor care nu sunt reprezentate în dicționar ca fiind anormale. Alte abordări au utilizat trăsături de tipul „deep” [23] sau filtre de tipul „locality sensitive hashing” [24] pentru a obține rezultate mai bune.



Unele abordări mai recente se bazează pe integrarea unor pași care nu necesită supervizare pentru detectarea evenimentelor anormale [7, 16, 22, 23]. Abordarea prezentată în [7] se bazează pe construirea unui model care să reprezinte evenimentele familiare din datele de antrenare și pe actualizarea incrementală a modelului într-un mod nesupervizat, pe măsură ce apar noi evenimente normale în datele de testare. Într-o manieră similară, autorii lucrării [22] antrenează un model de tipul „Growing Neural Gas” pornind de la fișierele video din setul de antrenare, continuând procesul de antrenare pe măsură ce fișierele video din setul de testare sunt analizate în vederea detectării evenimentelor anormale. Autorii lucrării [16] aplică o tehnică nesupervizată numită „spectral clustering” pentru a construi un dicționar de atomi, fiecare atom reprezentând un tip de comportament normal observat în fișierele video din setul de antrenare. Autorii lucrării [23] utilizează metoda „Stacked Denoising Auto-Encoders” pentru învăța o reprezentare de tipul „deep” într-o manieră nesupervizată. Deși trăsăturile sunt obținute într-un mod nesupervizat, autorii lucrării [23] aplică mai mulți clasificatori de tipul SVM pentru o singură clasă pentru a prezice scorurile de anomalie al evenimentelor din fișierele video de testare.

Anumite componente ale algoritmului bazat pe combinarea scorurilor ce formează obiectul cererii de brevet sunt similare cu cele descrise în lucrările [6, 8, 13, 21]. Lucrările [6, 13] sunt similare prin faptul că utilizează cuboizi spațio-temporali, totuși există o serie de diferențe. O primă diferență constă în faptul că în cazul lucrărilor [6, 13], trăsăturile utilizate în faza de antrenare și în cea de testare sunt obținute în urma aplicării unei analize în componente principale. Astfel, numărul de trăsături este redus de la 500 la 100. În cazul algoritmului nostru, utilizăm toate cele 500 de trăsături. O altă diferență constă în faptul că metoda noastră presupune augmentarea cuboizilor cu informații suplimentare despre locația lor în fiecare cadru și despre direcția medie conținută în fiecare cuboid. Aceste informații suplimentare conduc la o performanță mai bună a sistemului. Totodată, trăsăturile care modeleză mișcarea din cuboizi sunt combinate cu trăsături extrase cu ajutorul rețelelor neuronale convoluționale care modeleză înfățișarea sau postura obiectelor. O altă diferență constă în modul de utilizare al acestor trăsături în faza de antrenare. Autorii lucrării [13] codifică structurile redundante înglobate în cuboizi printr-o mulțime de combinații ale unor vectori de bază. Abordarea propusă în [6] constă în detectare schimbărilor apărute într-o secvență de video la un moment de timp, prin comparație cu toate cadrele anterioare preluate de camera video. Această abordare este una nesupervizată, nefiind necesară utilizarea unor fișiere video de antrenare. Pe de altă parte, abordarea nu poate fi folosită pentru a analiza fișierele video în timp real, deoarece autorii creează permutări aleatoare ale cadrelor analizate pentru a elimina dependența temporală a metodei lor. Spre deosebire de [6, 13], algoritmul propus se bazează pe o metodă originală de eliminare a valorilor aberante în două etape. În prima etapă, utilizăm algoritmul k-means pentru a genera și selecta grupuri de cuboizi ce reprezintă mișcarea și postura normală a obiectelor. În a doua etapă, antrenăm mai mulți clasificatori SVM adaptati pentru probleme cu o singură clasă. Fiecare clasificator va reprezenta un model de mișcare și postură familiară a obiectelor din video.

De menționat este că ideea combinării trăsăturilor ce reprezintă mișcarea din video cu trăsăturile ce reprezintă înfățișarea sau postura obiectelor a fost studiată în [8]. Totuși, abordarea propusă în [8] constă în combinarea scorurilor obținute în urma analizei independente a celor două tipuri de trăsături. Obiectul prezentei cererii de brevet este un algoritm nou și diferit prin care cele două tipuri de trăsături se pot combina într-un mod eficient, atât din punct de vedere al acurateței cât și al timpului de calcul. Mai precis, combinare trăsăturilor se realizează înainte de etapa de antrenare, nefiind nevoie de o procesare separată a trăsăturilor. Totodată, abordarea descrisă în [8] se bazează pe utilizarea tehnicii de „unmasking” [10] pentru detectarea evenimentelor într-un mod nesupervizat. Deși nu necesită fișiere video pentru antrenare, abordarea descrisă în [8] produce, în general, rezultate mai slabe



decât cele ale unei tehnici supervizate, de tipul celei folosite în cadrul algoritmului propus și descrisă în continuare. O altă abordare similară cu algoritmul propus este descrisă în [21]. Spre deosebire de algoritm bazat pe combinarea trăsăturilor ce reprezintă mișcarea din video cât și a trăsăturilor ce reprezintă postura obiectelor, abordarea propusă în lucrarea [21] utilizează doar trăsăturilor ce reprezintă postura obiectelor. Totodată, metoda supervizată din [21] se bazează pe antrenarea unui singur clasificator SVM pentru o clasă, în timp ce algoritmul nostru utilizează o metodă de antrenare diferită și originală, fiind formată din două etape.


3. Algoritmul bazat pe combinarea scorurilor

Algoritmul propus pentru detectarea și localizarea evenimentelor anormale din video se bazează pe extragerea a două tipuri de trăsături, unele care reprezintă mișcarea obiectelor și altele care reprezintă înfățișarea sau postura obiectelor. Trăsăturile extrase sunt combinate la nivel local, rezultând o mulțime de cuboizi spațio-temporali. Antrenarea algoritmului este formată din două etape succesive. În prima etapă, utilizăm algoritmul k-means pentru a genera și selecta grupuri de cuboizi ce reprezintă mișcarea și postura normală a obiectelor. În a doua etapă, antrenăm mai mulți clasificatori SVM adaptati pentru probleme cu o singură clasă, câte un clasificator pe fiecare grup obținut în prima etapă de antrenare. În faza de testare, clasificatorii se aplică pe cuboizi rezultați din fișierele video de test. Pentru fiecare exemplu considerăm scorul de anomalie ca fiind maximul dintre scorurile întoarse de clasificatorii SVM. Etapele algoritmului sunt ilustrate în Figura 1. În continuare, sunt descrise modul de extragere al celor două tipuri de trăsături, procesul de antrenare format din două etape, precum și metoda de calculare a scorurilor.

3.1. Extragerea trăsăturilor ce reprezintă mișcarea obiectelor

Fiind dat un fișier video cu rezoluție mai mare de 320 (lățime) x 240 (înălțime) pixeli și cu un număr între 15 și 30 de cadre pe secundă, având un număr total de N cadre, se execută următorii pași pentru obținerea trăsăturilor de mișcare:

- În cazul în care cadrele sunt reprezentate în format color, se transformă fiecare imagine cadru păstrând doar intensitatea pixelilor, rezultând o imagine cadru reprezentată prin nivelurile de gri, între 0 și 255.
- Se aplică un filtru Gaussian de dimensiune 7x7 cu magnitudine 1.2 pentru eliminarea zgromotului din fiecare cadru (frame).
- Se redimensionează fiecare cadru din video la dimensiunea 160 x 120 de pixeli utilizând metoda de interpolare biliniară pentru aproximarea valorilor pixelilor.
- Se estimează gradienții de mișcare din fiecare două cadre consecutive, prin calcularea diferențelor în modul între valorile pixelilor corespunzători celor două cadre consecutive, aşa cum rezultă din Figurile 2 și 3. Din cele N cadre al fișierului video, în urma acestui pas, rezultă N – 1 „cadre-gradient” ale căror pixeli indică magnitudinea gradienților de mișcare a obiectelor în video.
- După calcularea gradienților pe întreaga dimensiune spațială a fișierului video (160 x 120), se trece la extragerea cuboizilor spațio-temporali. Pe dimensiunea spațială, fiecare cadru-gradient se împarte în regiuni adiacente de 10 x 10 pixeli, ca în Figura 4.
- Regiunile aflate în aceeași poziție în fiecare 5 cadre-gradient consecutive, sunt stivuite pentru a obține un cuboid 3D de dimensiune 10 x 10 x 5. Din fiecare 5 cadre-gradient consecutive, rezultă un număr de 16 x 12 = 192 de cuboizi.



- g) Fiecare cuboid rezultat conține gradienții de mișcare 3D dintr-o regiune relativ mică din video. Totuși, dacă regiunea respectivă este aproape statică pe durata celor 5 cadre din care a fost extras cuboidul, atunci se recurge la eliminarea cuboidului prin aplicarea unui prag minim asupra sumei dată de componente cuboidului, componente ce indică magnitudinea gradienților de mișcare.
- h) Pentru etapa de antrenare a clasificatorului SVM, fiecare cuboid păstrat este liniarizat sub forma unui vector de 500 de componente ce conține trăsături de mișcare.
- i) Fiecare vector este normalizat prin împărțirea fiecărei componente din vector la norma L_2 a vectorului. Fiind dat un vector $x = (x_1, x_2, \dots, x_m)$, obținem vectorul normalizat conform următoarei formule:

$$\hat{x} = \frac{x}{\sqrt{x_1^2 + x_2^2 + \dots + x_m^2}}. \quad (1)$$

Cuboizii astfel obținuți sunt augmentați cu informații suplimentare despre locația lor spațială, aplicând următorii pași:


- a) Pe dimensiunea spațială, fiecare cadru-gradient (de 160×120 pixeli) se împarte în 4×4 regiuni adiacente de 40×30 pixeli. Astfel, fiecare regiune spațială va conține cel mult 4×3 cuboizi.
- b) Fiecare regiune spațială este etichetată cu un număr de la 1 la 16.
- c) Se adaugă la reprezentarea fiecărui cuboid 16 componente egale cu 0, rezultând astfel un vector de 516 componente.
- d) Pentru fiecare cuboid se asociază valoarea 1 acelei componente (din cele 16 adăugate la pasul anterior) care corespunde etichetei regiunii spațiale care conține cuboidul respectiv, așa cum se explică în Figura 5.

Totodată, fiecare cuboid este augmentat și cu o histogramă ce codifică direcția medie a mișcării conținute în cuboidul respectiv. Pentru estimarea direcției medii și codificarea sub formă de histogramă, se aplică următorii pași:

- a) Se consideră separat fiecare regiune de 10×10 pixeli din cele 5 regiuni consecutive care formează un cuboid spațio-temporal.
- b) Se calculează centrul de greutate al gradienților de mișcare conținuți în fiecare regiune în parte.
- c) Luând regiunile consecutive, două câte două, se calculează diferența între centre de greutate pe cele două axe (orizontală și verticală), rezultatul fiind interpretat ca un vector ce codifică direcția de mișcare între două regiuni consecutive.
- d) Spațiul 2D în care sunt reprezentați vectorii de mișcare este împărțit în 8 cadrane disjuncte de 45° fiecare.
- e) Pentru cele 8 cadrane construim o histogramă cu 8 componente, având inițial toate componentele cu valoarea 0.
- f) Fiecare vector de mișcare este încadrat într-unul din cele 8 cadrane, iar magnitudinea vectorului de mișcare este adunată la componenta corespunzătoare din histogramă, așa cum este ilustrat în Figura 6. Magnitudinea vectorului x este dată de:

$$mag_x = \sqrt{x_1^2 + x_2^2}. \quad (2)$$

- g) Întregul proces se repetă prin împărțirea spațială a fiecărui cuboid în 2×2 subcuboizi de $5 \times 5 \times 5$ componente, calculând centrul de greutate al fiecărui subregiuni de 5×5 în parte.



- h) Împreună cu histograma de 8 componente, mai adăugăm o componentă care conține suma magnitudinii tuturor vectorilor de mișcare.
- i) În totală, sunt 9 componente care se adaugă la reprezentarea fiecărui cuboid, rezultând un număr total de 525 de componente.


Vectorii care conțin trăsături de mișcare, rezultați în urma procesării fișierelor video de antrenare, sunt concatenați cu vectorii care conțin trăsături de postură a obiectelor. Pentru etapa în care se aplică algoritmul de detectare a evenimentelor anormale pe fișiere video noi (de testare), vectorii de trăsături trebuie calculați, în prealabil, din fișierele video ce trebuie analizate în vedere detectării evenimentelor anormale.

3.2. Extragerea trăsăturilor ce reprezintă postura obiectelor

Pentru extragerea obținerea trăsăturilor ce modeleză înfățișarea și postura obiectelor din video, se utilizează o rețea neuronală convoluțională pre-antrenată pe setul de date ImageNet [17] pentru recunoașterea obiectelor din imagini. Arhitectura rețelei pre-antrenate este de tipul VGG-f [3]. Configurația acestei arhitecturi de rețea convoluțională este detaliată în Figura 7. În vederea utilizării rețelei pentru extragerea trăsăturilor din video, se elimină cele 7 straturi de la sfârșit (cu indecsii 15 până la 21), păstrând doar starturile de la intrarea rețelei până la stratul denumit „relu5” (cu indecsii 0 până la 14).

Fiind dat un fișier video cu rezoluție mai mare de 320 (lățime) x 240 (înălțime) pixeli și cu un număr între 15 și 30 de cadre pe secundă, având un număr total de N cadre, se execută următorii pași pentru obținerea trăsăturilor ce modeleză înfățișarea și postura obiectelor din video:

- a) Se aplică un filtru Gaussian de dimensiune 3x3 cu magnitudine 1 pentru eliminarea zgomotului din fiecare cadru.
- b) Se redimensionează fiecare cadru din video la dimensiunea 224 x 244 de pixeli utilizând metoda de interpolare biliniară pentru aproximarea valorilor pixelilor.
- c) În cazul în care cadrele sunt reprezentate prin nivelurile de gri, se produce o imagine color cu 3 canale (RGB) corespunzătoare fiecărui cadru, prin copierea valorilor pixelilor inițiali pe fiecare canal în parte. În cazul în care fișierul video este color, acest pas nu este necesar.
- d) Din fiecare cadru color de 224 x 224 se scade imaginea medie a rețelei convoluționale. Imagine medie se obține din setul de imagini de antrenare, prin calcularea valorii medii pentru fiecare pixel, prin însumarea valorilor din toate imaginile și apoi, prin împărțirea sumei corespunzătoare fiecărui pixel la numărul de imagini din setul de antrenare. De menționat că toate imaginile din setul de antrenare au 224 x 224 pixeli.
- e) După scăderea imaginii medie, cadrul este copiat pe stratul de input al rețelei convoluționale prezentate în Figura 4. După aplicarea operațiilor corespunzătoare straturilor 1-14, se obține un tensor (matrice 3D) de dimensiune 13 x 13 x 256.
- f) Se redimensionează fiecare tensor la dimensiunea 16 x 12 x 256 utilizând metoda de interpolare biliniară pentru aproximarea valorilor.
- g) Fiecare vector de dimensiune 1 x 1 x 256 este normalizat prin împărțirea fiecărei componente din vector la norma L₂ a vectorului, ca în Ecuația (1).
- h) În final, fiecare vector de 256 de componente de la poziția (x,y) din cardul t este concatenat cu cuboidul corespunzător, anume cuboidul de la poziția (x,y) din cardul t, unde x este un număr natural între 1 și 16 iar y este un număr natural între 1 și 12. Rezultatul este un vector cu 256 + 525 = 781 componente.



Pentru etapa în care se aplică algoritmul de detectare a evenimentelor anormale pe fișiere video noi (de testare), vectorii de 781 componente trebuie calculați, în prealabil, din fișierele video ce trebuie analizate în vedere detectării evenimentelor anormale.

3.3. Prima etapă de antrenare: Eliminarea anomalilor folosind k-means

În prima etapă de antrenare, aplică un algoritm nesupervizat pentru gruparea cuboizilor spațio-temporali, ce conțin atât trăsături de mișcare cât și trăsături de postură a obiectelor, obținuți din fișierele video de antrenare pentru a găsi grupuri ce reprezintă diferite tipuri de mișcări și posturi normale ale obiectelor din video. Următorul pas constă în eliminarea grupurilor cu mai puțini cuboizi, pe baza presupunerii că aceste grupuri conțin în cea mai mare parte valori aberante. Pentru a susține această presupunere, considerăm exemplul ilustrat în Figura 8 cu 400 de exemple (cercuri roșii) provenite dintr-o mixtură de două distribuții normale de medii diferite. Exemplile generate sunt grupate în 30 de grupuri cu algoritmul k-means. Numărul de exemple din fiecare cluster este prezentat în histograma din Figura 9. În acest exemplu, am considerat că grupurile cu mai puțin de 10 exemple trebuie eliminate. Centroizii acestor grupuri sunt marcați cu un pătrat albastru în Figura 8. Spre deosebire, centroizii grupurilor care rămân sunt marcați cu un disc albastru. În acest exemplu, putem observa cu ușurință faptul că grupurile marcate pentru eliminare sunt într-adevăr cele care conține valori aberante. Aceste grupuri reprezintă fie elemente de mișcare sau postură a obiectelor mai puțin reprezentative sau care conțin mai mult zgomot.

În exemplu prezentat în Figura 8, algoritmul k-means și pasul de eliminare al grupurilor cu mai puține exemple sunt aplicate pe un set de vectori cu două componente (punkte în plan). În cadrul algoritmului de detectare a evenimentelor anormale, algoritmul k-means și pasul de eliminare sunt de fapt aplicate pe vectori de 781 componente (cuboizi spațio-temporali). În practică, numărul de clustere se poate determina în mod automat în funcție de numărul total de cuboizi astfel încât să rezulte în medie un număr de p de cuboizi în fiecare grup. Experimental, am determinat că valorile potrivite pentru p sunt între 1.000 și 10.000. Tot experimental, am stabilit că pragul pentru eliminarea grupurilor de cuboizi este $p / 2$.

3.4. A doua etapă de antrenare: Eliminarea anomalilor folosind SVM pentru o singură clasă

După eliminarea grupurilor cu mai puțini cuboizi, rămân o mulțime de grupuri $C = \{c_1, c_2, \dots, c_r \mid r \leq k\}$ care modeleză mișările și postura obiectelor reprezentative din punct de vedere al normalității. Totuși, algoritmul k-means nu produce o graniță suficient de strânsă în jurul fiecărui grup din C , astfel că un grup poate cuprinde și valori aberante. De exemplu, granița unor grupuri care rămân după eliminare din Figura 8 se continuă spre infinit. Pentru a soluționa această problemă, a doua etapă de antrenare constă în antrenarea unor clasificatori SVM pentru o singură clasă conform [19], pentru a determina granițe de separare mai strânse în jurul grupurilor rămase. Pentru a antrena clasificatorii, considerăm că fiecare cuboid spațio-temporal este un exemplu de antrenare independent de celelalte, neluând astfel în considerare relațiile spațiale și temporale dintre cuboizi. Considerăm mulțimea de antrenare $\mathcal{X} = \{x_1, x_2, \dots, x_n \mid x_i \in \mathbb{R}^m\}$ formată din vectorii de 781 de trăsături dintr-un grup c_j . În această formulare, clasificatorul SVM pentru o singură clasă va învăța să separe o regiune restrânsă ce cuprinde un tip cuboizi normali (familiali) de restul spațiului de trăsături, prin maximizarea distanței de la origine la hiperplanul de separare al clasificatorului SVM. În urma antrenării clasificatorului SVM, va rezulta o funcție de clasificare binară g , ce va produce un eticheta +1 pentru regiunile

din spațiul de trăsături ce aparțin densității de probabilitate a evenimentelor normale și eticheta -1 în rest. Funcția învățată are forma:

$$g(z) = \text{sign} \left(\sum_{i=1}^n \alpha_i \cdot k(z, x_i) - \rho \right), \quad (3)$$

unde $x_i \in X$ este un exemplu (cuboid) de antrenare, k este o funcție nucleu, α_i sunt ponderile asociate vectorilor suport x_i , ρ este distanța de la origine la hiperplan, iar z este un exemplu (cuboid) de test ce trebuie clasificat într-o din cele două clase de evenimente: normal sau anormal. Coeficienții α_i sunt stabiliți prin găsirea soluției următoarei probleme duale:

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \cdot \alpha_j \cdot k(x_i, x_j) \text{ cu } 0 \leq \alpha_i \leq \frac{1}{v \cdot n}, \sum_{i=1}^n \alpha_i = 1, \quad (4)$$

unde $v \in [0,1]$ este parametrul de regularizare al clasificatorului SVM, prin intermediul căruia se controlează procentajul de valori aberante (anomalii) ce trebuie excluse din modelul de familiale învățat. Distanța de la origine la hiperplan ρ poate fi găsită prin exploatarea proprietății satisfăcute de un exemplu x_i , pentru orice α_i care nu reprezintă o limită inferioară sau o limită superioară, conform [19]:

$$\rho = \sum_{j=1}^n \alpha_j \cdot k(x_j, x_i). \quad (5)$$

Funcția nucleu k pe care o utilizăm în clasificatorul SVM este funcția nucleu liniară, dată de produsul scalar între două exemple x și z :

$$k(x, z) = \langle x, z \rangle. \quad (6)$$

În vedere obținerii un scoruri care să reflecte gradul de anomalie al fiecărui cuboid, renunțăm la funcția semn (sign) din Ecuăția (3). De menționat că pentru fiecare grup de cuboizi c_j din C , vom avea câte un clasificator cu funcția de scor asociată g_{c_j} . Aplicând apoi clasificatorii SVM pe un cuboid extras din fișierul video de testare vom obține o mulțime de r scoruri de normalitate. Deoarece grupurile de cuboizi sunt independente (apartin unor zone disjuncte din spațiul de trăsături), putem presupune în mod natural că fiecare cuboid de test poate apartine unui singur grup de cuboizi. Astfel, dintre cele r scoruri, alegem scorul maxim de normalitate, adică scorul asociat grupului care este cel mai apropiat de cuboidul de test. Dacă scorul maxim este pozitiv, înseamnă că grupul cel mai apropiat cuprinde cuboidul de test. Dacă scorul maxim este negativ, înseamnă că niciun grup nu cuprinde cuboidul de test, în această situație, cuboidul respectiv fiind considerat a fi anormal. Această procedură se aplică fiecarui cuboid de test.

3.5. Calcularea scorurilor de anomalie la nivel de cadru și la nivel de pixel

Pentru a interpreta scorul maxim de normalitate al unui cuboid de test ca scor de anomalie schimbăm semnul scorului. Punând împreună scorul cuboizilor din fiecare cadru, obținem o mapare cu 16×12 componente de predicție (scoruri de anomalie) pentru fiecare cadru. Pentru a obține o mapare cu predicții la nivel de pixel, redimensionăm maparea de 16×12 componente la dimensiunea fișierului video de testare utilizând metoda de interpolare biliniară. Pentru a obține scoruri de predicție la nivel de cadru, alegem scorul maxim de anomalie din maparea de 16×12 componente. Pe axa temporală, aplicăm un filtru Gaussian pentru a netezi scorurile la nivel de cadru. În practică, am obținut rezultate mai bune cu filtre Gaussiane cu suport de la 20 până la 100 de componente. În final, evenimentele anormale sunt detectate în urma aplicării unui prag pe scorurile de anomalie la nivel de cadru. Cadrele consecutive care depășesc pragul de anomalie se consideră că formează un singur eveniment.


anormal. Pragul de anomalie poate fi ajustat în funcție de aplicație pentru a obține raportul dorit dintre detecțiile adevărate și cele false.

3.6. Elemente de noutate ale algoritmului propus

Algoritmul pentru detectarea evenimentelor anormale conține o serie de elemente de noutate:

- Metoda de augmentare a cuboizilor spațio-temporali cu informații despre locație și despre mișcare medie (descrisă în secțiunea 3.1.).
- Metoda de calcul a trăsăturilor pentru postura obiectelor (descrisă în secțiunea 3.2.).
- Metoda de eliminare a valorilor aberante folosind algoritmul k-means în prima etapă de antrenare (descrisă în secțiunea 3.3.).
- Metoda de calculare a scorului de anomalie pentru fiecare cuboid de test (descrisă în secțiunea 3.4.).

4. Referințe

- [1] Adam, A., Rivlin, E., Shimshoni, I., Reinitz, D.: Robust Real-Time Unusual Event Detection Using Multiple Fixed- Location Monitors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(3), 555–560 (2008) 
- [2] Antic, B., Ommer, B.: Video parsing for abnormality detection. In: Proceedings of ICCV. pp. 2415–2422 (2011)  
- [3] Chatfield, K., Simonyan, K., Vedaldi, A., Zisserman, A.: Return of the Devil in the Details: Delving Deep into Convolutional Nets. In: Proceedings of BMVC (2014)  
- [4] Cheng, K.W., Chen, Y.T., Fang, W.H.: Video anomaly detection and localization using hierarchical feature representation and Gaussian process regression. In: Proceedings of CVPR. pp. 2909–2917 (2015)  
- [5] Cong, Y., Yuan, J., Liu, J.: Sparse reconstruction cost for abnormal event detection. In: Proceedings of CVPR. pp. 3449–3456 (2011)  
- [6] Del Giorno, A., Bagnell, J., Hebert, M.: A Discriminative Framework for Anomaly Detection in Large Videos. In: Proceedings of ECCV. pp. 334–349 (2016)  
- [7] Dutta, J.K., Banerjee, B.: Online Detection of Abnormal Events Using Incremental Coding Length. In: Proceedings of AAAI. pp. 3755–3761 (2015)  
- [8] Ionescu, R.T., Smeureanu, S., Alexe, B., Popescu, M.: Unmasking the abnormal events in video. In: Proceedings of ICCV (2017)
- [9] Kim, J., Grauman, K.: Observe locally, infer globally: A space-time MRF for detecting abnormal activities with incremental updates. In: Proceedings of CVPR. pp. 2921–2928 (2009)
- [10] Koppel, M., Schler, J., Bonchek-Dokow, E.: Measuring Differentiability: Unmasking 

Pseudonymous Authors. Journal of Machine Learning Research, vol. 8, 1261–1276 (2007)

[11] Krizhevsky, A., Sutskever, I., Hinton, G.E.: ImageNet Classification with Deep Convolutional Neural Networks. In: Proceedings of NIPS. pp. 1106–1114 (2012) 

[12] Li, W., Mahadevan, V., Vasconcelos, N.: Anomaly detection and localization in crowded scenes. IEEE Transactions on Pattern Analysis and Machine Intelligence 36(1), 18–32 (2014) 


[13] Lu, C., Shi, J., Jia, J.: Abnormal Event Detection at 150 FPS in MATLAB. In: Proceedings of ICCV. pp. 2720–2727 (2013) 

[14] Mahadevan, V., LI, W.X., Bhalodia, V., Vasconcelos, N.: Anomaly Detection in Crowded Scenes. In: Proceedings of CVPR. pp. 1975–1981 (2010) 

[15] Mehran, R., Oyama, A., Shah, M.: Abnormal crowd behavior detection using social force model. In: Proceedings of CVPR. pp. 935–942 (2009) 

[16] Ren, H., Liu, W., Olsen, S.I., Escalera, S., Moeslund, T.B.: Unsupervised Behavior-Specific Dictionary Learning for Abnormal Event Detection. In: Proceedings of BMVC. pp. 28.1–28.13 (2015) 

[17] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., A., K., Khosla, A., Bernstein, M., Berg, A.C., Fei-Fei, L.: ImageNet large scale visual recognition challenge. International Journal of Computer Vision (2015) 

[18] Saligrama, V., Chen, Z.: Video anomaly detection based on local statistical aggregates. In: Proceedings of CVPR. pp. 2112–2119 (2012) 

[19] Schölkopf, B., Platt, J.C., Shawe-Taylor, J.C., Smola, A.J., Williamson, R.C.: Estimating the support of a high-dimensional distribution. Neural Computation 13(7), 1443–1471 (Jul 2001)

[20] Simonyan, K., Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition. In: Proceedings of ICLR (2014)

[21] Smeureanu, S., Ionescu, R.T., Popescu, M., Alexe, B.: Deep Appearance Features for Abnormal Behavior Detection in Video. In: Proceedings of ICIAP (2017)

[22] Sun, Q., Liu, H., Harada, T.: Online growing neural gas for anomaly detection in changing surveillance scenes. Pattern Recognition 64(C), 187–201 (2017) 


[23] Xu, D., Ricci, E., Yan, Y., Song, J., Sebe, N.: Learning Deep Representations of Appearance and Motion for Anomalous Event Detection. In: Proceedings of BMVC. pp. 8.1–8.12 (2015) 



[24] Zhang, Y., Lu, H., Zhang, L., Ruan, X., Sakai, S.: Video anomaly detection based on locality sensitive hashing filters. *Pattern Recognition* 59, 302–311 (2016) 

[25] Zhao, B., Fei-Fei, L., Xing, E.P.: Online Detection of Unusual Events in Videos via Dynamic Sparse Coding. In: *Proceedings of CVPR*. pp. 3313–3320 (2011)

Anexa 1 – Figura 1



Metodă și algoritm bazat pe gradienți de mișcare și rețele neuronale convoluționale pentru detectarea și localizarea automată a evenimentelor anormale din video

Aplicant:

SecurifAI
Bd. Mircea Vodă Nr. 24
București, Romania

Revendicare:

Metoda și algoritmul bazat pe gradienți de mișcare și rețele neuronale convoluționale pentru detectarea și localizarea automată a evenimentelor anormale din video se caracterizează prin aceea că se bazează pe două tipuri de trăsături, unele care reprezintă mișcarea obiectelor cât și pe trăsături care reprezintă înfațarea sau postura obiectelor sau a persoanelor.

Securifai SRL
Prin administrator
Vlad Mihu






Figura 1. Etapele prevăzute în algoritmul pentru detectarea și localizarea evenimentelor anormale din video pe baza unei metode de eliminare a valorilor aberante formată din două etape de antrenare. Metoda combină trăsăturile ce reprezintă mișcarea obiectelor și trăsăturile ce reprezintă postura obiectelor prin intermediul unor cuboizi.

Anexa 2 – Figura 2

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	1	1	1	1	1	0	0	0
0	1	1	1	1	1	0	0	0
0	1	1	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

C_i

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	1	1	1	1	0	0	0
0	1	0	0	0	1	0	0	0
0	1	0	0	0	1	0	0	0
0	1	1	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

C_{i+1}

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	1	1	1	1	0	0	0
0	1	0	0	0	1	0	0	0
0	1	0	0	0	1	0	0	0
0	1	1	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

$CG_i = |C_i - C_{i+1}|$

Figura 2. Pentru orice două cadre consecutive C_i și C_{i+1} , se calculează cadrul-gradient CG_i ca diferență în modul între pixelii din cadrul C_i și cadrul C_{i+1} . În cadrul C_i avem un obiect pătrat format din pixeli cu valoarea 1, care se deplasează spre dreapta sus în cadrul următor C_{i+1} . Cadrul-gradient CG_i conține magnitudinea gradienților de mișcare ai obiectului pătrat. În acest exemplu ilustrativ, cadrele au 8 x 8 pixeli, dar în practică, procedura se aplică pe cadre de 160 x 120 pixeli.




Figura 3. Pentru orice două cadre consecutive C_i și C_{i+1} , se calculează cadrul-gradient CG_i ca diferență în modul între pixelii din cadrul C_i și cadrul C_{i+1} . În cadrul C_i avem o intersecție prin care trec mașini, care se deplasează în cadrul următor C_{i+1} . Cadrul-gradient CG_i conține magnitudinea gradientilor de mișcare ai mașinilor. În acest exemplu, cadrele au 160 x 120 pixeli.

Anexa 4 – Figura 4




Figura 4. Cadrul-gradient CG_i de 160 x 120 de pixeli din Figura 2 este împărțit în regiuni adiacente de 10 x 10 pixeli, rezultând un număr de 16 x 12 = 192 de regiuni. Împărțirea pe regiuni este ilustrată printr-o grilă de culoare roșie aplicată peste cadrul-gradient CG_i.

Anexa 5 – Figura 5

Călin




Figura 5. Pentru codificarea locației unui cuboid, se construiește un vector cu 16 componente cu 15 valori de 0 și o singură valoare de 1 ce corespunde regiunii spațiale din care provine cuboidul. În acest exemplu, toții cuboizii din regiunea 10 sunt augmentați cu vectorul de 16 componente în care valoarea 1 se află pe poziția 10.




Figura 6. Pentru codificarea direcției medii a unui cuboid de $10 \times 10 \times 5$ componente, luăm regiunile consecutive, două câte două, și calculăm diferența între centre de greutate pe cele două axe (orizontală - Ox și verticală - Oy), rezultatul fiind interpretat ca un vector ce codifică direcția de mișcare între două regiuni consecutive. Planul în care sunt reprezentați vectorii se împarte în 8 cadrane egale. Adunăm magnitudinea fiecărui vector de mișcare la componenta din histogramă ce corespunde cadranelui în care se află vectorul respectiv.

Index	Tip	Nume	Suport	Adâncime filtre	Număr filtre	Spațiere	Distanță margini	Dimensiune date	Adâncime date
0	input	-	-	-	-	-	-	224 x 224	3
1	conv	conv1	11 x 11	3	64	4	0	54 x 54	64
2	relu	relu1	1 x 1	-	-	1	0	54 x 54	64
3	norm	norm1	1 x 1	-	-	1	0	54 x 54	64
4	maxpool	pool1	3 x 3	-	-	2	0, 1, 0, 1	27 x 27	64
5	conv	conv2	5 x 5	64	256	1	2	27 x 27	256
6	relu	relu2	1 x 1	-	-	1	0	27 x 27	256
7	norm	norm2	1 x 1	-	-	1	0	27 x 27	256
8	maxpool	pool2	3 x 3	-	-	2	0	13 x 13	256
9	conv	conv3	3 x 3	256	256	1	1	13 x 13	256
10	relu	relu3	1 x 1	-	-	1	0	13 x 13	256
11	conv	conv4	3 x 3	256	256	1	1	13 x 13	256
12	relu	relu4	1 x 1	-	-	1	0	13 x 13	256
13	conv	conv5	3 x 3	256	256	1	1	13 x 13	256
14	relu	relu5	1 x 1	-	-	1	0	13 x 13	256
15	maxpool	pool5	3 x 3	-	-	2	0	6 x 6	256
16	conv	fc6	6 x 6	256	4096	1	0	1 x 1	4096
17	relu	relu6	1 x 1	-	-	1	0	1 x 1	4096
18	conv	fc7	1 x 1	4096	4096	1	0	1 x 1	4096
19	relu	relu7	1 x 1	-	-	1	0	1 x 1	4096
20	conv	fc8	1 x 1	4096	1000	1	0	1 x 1	1000
21	softmax	softmax	1 x 1	-	-	1	0	1 x 1	1000

Figura 7. Configurația rețelei neuronale conoluționale utilizată pentru extragerea trăsăturilor ce modelează înfățișarea și postura obiectelor dintr-un cadru al fișierului video. După antrenarea rețelei, straturile 15-21 se elimină. În urma procesării unui cadru, rezultă un tensor de dimensiune 13 x 13 x 256, conform stratului relu5.

Legendă:

input = strat de intrare (o imagine RGB de 224 x 224 pixeli)

conv = strat conoluțional (presupune aplicarea operației de conoluție)

relu = strat non-liniar (presupune aplicarea funcției $f(x) = \max(0, x)$)

norm = strat de normalizare (presupune normalizarea răspunsului local)

maxpool = strat de pooling (presupune păstrarea valorii maxime din fiecare regiune de 3 x 3)

softmax = stratul de decizie (presupune aplicarea funcției de decizie softmax)




Figura 8. O mulțime de 400 de puncte în plan provenite din două distribuții normale de medii diferite. Punctele sunt clusterizate în 30 de grupuri folosind algoritmul k-means. Centroizii grupurilor ce conțin mai puțin de 10 exemple sunt marcați cu pătrate albastre. Aceste grupuri conțin valori aberante (depărtate de mediile distribuțiilor normale).

Anexa 9 – Figura 9

A handwritten signature in blue ink, appearing to read "Iulian".




Figura 9. O histogramă cu numărul de puncte din fiecare grup de puncte reprezentat în Figura 8. Prin aplicarea unui prag de 10 puncte peste histogramă se obțin grupurile cu valori aberante.