

חיפוש תמונות מונחה דימיון-מימוש MLBP

מאת: הדר נגר

בסיכום זה אכתוב על פרויקט הגמר שלי שנעשה במכללה האקדמית להנדסה בבית הכרם במסגרת תואר ראשון בהנדסת תוכנה.

הפרויקט הוזמן ע"י חוליית אלבום במחלקת זיהוי פלילי (מז"פ) של משטרת ישראל. המחלקה עוסקת באיסוף ובעיבוד מוצגים הקשורים לעבירות וכן בזיהוי בני אדם לפי סימני זיהוי ביומטריים (תצלום DNA וטביעות אצבע).

זיהוי חשודים על ידי עדים שראו אדם מבצע עבירה נעשה על ידי הצגת תצלומים של חתך אוכלוסייה אשר מתאים לתיאור שנמסר וכן על ידי מאפייני העבירה. המערכת תכלול חיפוש שיבנה על עיקרון הדמיון, כאשר המטרה הינה להציג את מינימום התמונות הדרושות לצורך הגעה לתמונה של הפנים אותם ראה המזהה. לדוגמא, המזהה ראה אדם אך הוא אינו יודע שמו. אנו מעוניינים להציג לו את מינימום התמונות הנדרשות על מנת להגיע לתמונתו של האיש ומכאן לגלות את שמו.

הקלט לתוכנה: תמונה של חשוד
הפלט: כל התמונות שדומות לתמונת החשוד, על הפלט להיות מינימאלי ככל הניתן.

דרישת המשטרה הינה להסתמך על מאמר [1],
במאמר זה החוקרים פיתחו אלגוריתם להתאמת קלסטרון מצויר לתמונה, בעוד שבפרויקט אצטרך לממש התאמה של תמונה לתמונה.

בעיות בזיהוי פנים:

- אנו לא מעוניינים בהשוואת תמונות אלא השוואת האדם בתמונה לאדם בתמונה אחרת
- זוויות צילום שונות
- תנאי תאורה שונים
- חפצים המסתירים את הפנים: משקפיים, זקן, שפם
- שינויים פיזיים בפנים: פצעים, שריטות, מכות.

ולכן צריך לייצג את הפנים של האדם בצורה מתמטית אשר מושפעת בצורה מינימאלית ע"י התנאים המקשים המתוארים לעיל.

את הייצוג המתמטי אפשר להשוואת, לפי קריטריון קבלה הנקבע מראש – לעולם לא תהיה זהות מלאה כיוון שאין אפשרות לבטל את כלל התנאים הסביבתיים המשנים את מראה הפנים בתמונות

נסביר בקצרה את האופרטור הבסיסי **LBP- Local Binary Pattern** שפרויקט הרחבתי אותו (MLBP).

אופרטור lbp בסיסי:

אופרטור ה Local Binary Pattern (LBP) הוצג לראשונה ע"י Ojala et al [2] שהראה את הכוח הגדול לסיווג מרקם.

לכל פיקסל נתון (X_c, Y_c) , LBP מוגדר כסט מסודר של השוואות בינאריות בין הפיקסל המרכזי לשכניו שמסובבים אותו.

שלב האלגוריתם

שלב 1 : נרמול התמונה:

- ✓ זווית בין שתי העיניים שווה ל0
- ✓ מרחק בין העיניים של 75 פיקסלים
- ✓ גודל תמונה : 250X200 פיקסלים.

שלב 2 : MLBP

האלגוריתם:

1. חילוק התמונה ל $M \times N$ ריבועים שווים (על דרך הבחירה).
2. בחירת משתנים P, R :
 P – מספר השכנים לכל פיקסל ($P = 8$)
 R – רדיוס ($R = 1, 3, 5, 7$).
3. הרצת LBP לכל ריבוע בנפרד ארבע פעמים:
 3.1. ביצוע thresholding לכל פיקסל בריבוע.
 3.2. שקלול תוצאות ה thresholding לערך אחיד לכל P שכנים.
 3.3. קבלת ווקטור באורך 59 איברים לתמונה לכל רדיוס.
 (לאחר צמצום uniform patterns – פירוט למטה – איור 2).
 3.4. שרשור ארבעת הווקטורים לווקטור אחד של 236.

שלב 3: הפיכת הווקטור להיסטוגרמה ונרמול שלה.

שלב 4: השוואה ולקיחת 100 התמונות עם התוצאות הטובות.

בעיות מבחינת הנדסת תוכנה:

גמישות- על מימוש האלגוריתם והקוד להיות נוח לשינויים ולעדכונים - לשם כך יש להגדיר באופן ברור את שלבי האלגוריתם ושמידת כל שלב להיות עצמאי ככל הניתן מהשלבים האחרים כך שניתן יהיה לשנות בבוא הצורך חלקים ללא פגיעה בחלקים האחרים.

זמן ריצה- חישוב MLBP 4 פעמים לכל תמונה לוקח $0.10368 \times 4 = 0.414$ sec

ל 500 תמונות לוקח 207 שניות שהן 3.4 דקות.

כלומר ל 500 תמונות הזמן שלוקח נרמול + MLBP זה 10.414 .

במאגר המשרטה ישנם בערך 200,000 , כלומר זמן הריצה הצפוי הינו 4165 דקות.

מצד שני זו פעולה שצריך לבצע מספר קטן של פעמים מכיוון שאנו מריצים את

פעם אחת בלבד ושומרים את הציונים לכל תמונה את ציון ה MLBP שלה.

uniform patterns-(איור 2)


הדרך לצמצום אורך ווקטור האפיון ומימוש rotation-invariant פשוט.

ההשראה של דרך זו היא התופעה של מחרוזות בינאריות שמכילות יותר מידע מאשר מחרוזות אחרות (קצוות ויותר מידע).

local binary pattern ייקרא אחיד אם המחרוזת כוללת לכל היותר שני מעברים של ביטים (bitwise transitions) מ 0 ל- 1 או ההפך כאשר המחרוזת מוזזת מעגלית. לדוגמה המחרוזת

00000000 (0 מעברים), 01110000 (2 מעברים)

ישנם כ 58 מחרוזות אחידות, נוסף 1 לכל המחרוזות הלא אחידות וקיבלנו ווקטור אפיון באורך 59 .



איור 2- 58 מחרוזות אחידות

[1] Brendan Klarea and Anil K Jaina, Matching Forensic Sketches to Mug Shot Photos.

[2] Ojala T, Pietikäinen M & Mäenpää T (2002) Multiresolution gray-scale and rotation invariant texture classification with Local Binary Patterns.