

IPARI CSOMAGOLÓGÉPEKBE ALKALMAZHATÓ KÉPFELDOLGOZÁSI ELJÁRÁSOK ÁTTEKINTÉSE

OVERVIEW OF IMAGE PROCESSING TECHNOLOGIES FOR INDUSTRIAL PACKAGING MACHINES

Pintér István^{1*}, Pásztor Attila¹, Koszna Ferenc¹,
Piller László¹, Vincze Imre¹

¹ Informatika Tanszék, GAMF Műszaki és Informatikai Kar, Neumann János Egyetem, Magyarország
<https://doi.org/10.47833/2022.2.CSC.002>

Kulcsszavak:

ipari képfeldolgozás
mintaillesztés
SVM, CNN
moduláris csomagológép

Keywords:

industrial image processing
pattern matching
SVM, CNN
modular packaging machine

Cikktörténet:

Beérkezett 2022. október 10.
Átdolgozva 2022. október 31.
Elfogadva 2022. november 5.

Összefoglalás

A moduláris felépítésű csomagológépekben számos esetben ipari képfeldolgozó rendszert alkalmaznak. A cikkben az általános célú ipari képfeldolgozó rendszer bemutatása után olyan képfeldolgozási eljárásokat ismertetünk, amelyek az ipari környezetben is jól beváltak. Ha a mintaillesztés esetében az előírt döntési pontossághoz nem biztosíthatóak a képvételi körülmények, akkor a változatosságot tanuló algoritmusokkal teszik kezelhetővé. Mivel a csomagolástechnikában a szupport vektor gép (SVM) és a konvolúciós neurális hálózat (CNN) alkalmazására találtunk szakirodalmi példát, ezeket ismertetjük.

Abstract

In the modular packaging machines industrial image processing system are used in many cases. In this paper the description of a general industrial image processing system is followed by the summary of those image processing techniques proved to be useful in the industry. When the specified decision accuracy can't be achieved in case of pattern matching, the variability is handled by learning algorithms. The SVM (Support Vector Machine) and CNN (Convolutional Neural Network) are discussed in the paper, because their applications are reported in relevant papers of packaging industry.

1. Bevezetés

A digitális képfeldolgozás eszköztárát régóta alkalmazzák az információ-technikában [1], [2], [3]. Napjainkban már olyan algoritmusok is vannak, amelyek lehetővé teszik képfeldolgozó funkciók beépítését az ipari berendezésekbe. A gyors alkalmazás-fejlesztés céljára intelligens kamerák széles választéka áll rendelkezésre. Ennek eredménye, hogy a mérési, osztályozási, naplózási feladatokon kívül elvárás lesz az ipar 4.0 követelményeinek való megfelelés is (utóbbira példa a "felhőbe" való csatlakozás képessége [4]). A cikk a moduláris ipari csomagológéphez fejlesztett képfeldolgozó mérőcellával kapcsolatos ismereteket foglalja össze.

* Kapcsolattartó szerző.
E-mail cím: pinter.istvan@gamf.uni-neumann.hu

2. Az általános célú ipari képfeldolgozó rendszer felépítése

A szakirodalomban ismertetett általános célú képfeldolgozó rendszer főbb összetevői a következők [3]: a megvilágítás eszközei, érzékelők a képvételhez, a képdigitalizálás eszközei, képfeldolgozó és képosztályozó algoritmusok, képfeldolgozó számítógép és szoftver, képmegjelenítő eszközök (például monitor, (színes) nyomtató), háttértár a naplózáshoz és archiváláshoz, kommunikációs eszközök az ipari számítógép-hálózathoz, végül eszközrendszer a "felhőbe" történő csatlakoztatásához.

2.1. Megvilágítás és képvétel

A leginkább elterjedt kamerás rendszerek esetében a képvétel a megvilágított tárgyról visszavert fényel történik. A megvilágítás és a képvétel követelményeit érdemes a megvilágító fény hullámhossza szerint áttekinteni. A csökkenő hullámhossz alapján adódnak a következő kategóriák: THz-es sugárzás, közeli infravörös fény, látható fény, ibolyán túli fény, röntgen- és gamma sugárzás. Ez utóbbi kettő ionizáló. Cikkünkben azzal az esettel foglalkozunk, amikor a megvilágító fényforrás spektruma a látható fény tartományába esik. A helyes képvétel előfeltétele a gondosan megtervezett és megvalósított megvilágítás. Ezáltal a képfeldolgozó algoritmusok számításigénye is csökkenthető. A változékony környezeti fény gyakran zavaró hatású, ezért a képvétel céljára a külső fénytől elzárt mérőcellát alakítanak ki. A megvilágítás főbb céljai közül a legfontosabb a képfeldolgozási feladat megoldása szempontjából lényeges jellemzők láthatóvá tétele a kamera számára, így például, ha bizonyos színű jellegzetességeket szeretnénk kiemelni, akkor használhatunk színes világítást is (esetleg nem az egyező, hanem a kiegészítő színnel).

A megvilágított tárgyról visszavert fény a kamera optikai rendszerén át jut a fényérzékelőre. Az érzékelő vagy töltéscsatolt eszköz (CCD, Charge-Coupled Device), vagy CMOS szenzor (Complementary Metal Oxide Semiconductor). A szenzorban síkbeli rács-elrendezésben található a fényérzékelő elemek, tehát a síkbeli diszkretizálás, mint a számítógépi feldolgozás egyik előfeltétele ezáltal teljesül. A rácspontokban lévő elektromos töltéseloszlás a fényintenzitással analóg. Ennek diszkretizálását analóg-digitális átalakítóval oldják meg. Az objektív által "látott" kép tehát képpontokból fog állni a kamerában. A végeredmény olyan mátrix, aminek elemei 8 bites nemnegatív egész számok. Képvételkor a szürkeárnyalatos kép esetében egyetlen mátrixot tudunk a kamerából kiolvasni, míg színes kép esetében hármat (a három alapszínnek megfelelően színcsatornánként egyet-egyét).

Az alapvető képfeldolgozó eljárásokat részletesen ismerteti a szakirodalom [1], [2], [3]. Ezekre támaszkodva az ipari alkalmazásokban már bevált módszereket csoportosítva foglalja össze Pietrzkievicz [5]. A főbb csoportok: kép szintre vágása, foltelemzés, élkeresés, kontúrelemzés, vonal- és kör detektálás, mintaillesztés. Ezek közül csak az utóbbit említjük meg külön, mert a legtöbb, ipari feladatok megoldásához ajánlott intelligens kamerában van ilyen funkció, amihez robosztus algoritmusok találhatóak a fejlesztő eszközökben. A mintaillesztés során a kijelölt képrészleten (ROI, Region Of Interest) kell megtalálni az előre megadott részképet. Ez utóbbit mintának nevezzük (angolul ezt 'template'-nek, illetve 'pattern'-nek nevezik). A mintaillesztés eredményképpen ennek előfordulási helyei adódnak, ideális esetben pozíció-, szöghelyzet- és méret-invariáns módon. Mivel az illeszkedés jóságának meghatározása számításigényes, bevált gyakorlat, hogy a mérőcellában a képvevő helyet előre rögzítik.

3. Ipari képosztályozás neurális hálózatokkal

Amint arra Gonzalez és Woods is rámutat könyvükben [3, p.473], olyan esetekben, amikor az osztályozandó objektumok (esetünkben az ellenőrizendő csomagok) pontosan ismertek, és a jó képvételhez biztosítható a megfelelő megvilágítás és pozíció, a mintaillesztés elfogadhatóan képes teljesíteni ipari körülmények között is. Ezeket a feltételeket a mérőcella gondos tervezésével és kivitelezésével lehet biztosítani.

Számos olyan ipari feladat létezik azonban, amelyknél ezek a feltételek nem teljesíthetők. Ilyen eset mindjárt az, amikor a csomagolás ellenőrzési feladat jól definiált ugyan, de az egyes csomagolási hibafajták mintaképei túlságosan is változatosak. Például szappandobozok épségének végellenőrzési feladata ilyen [7]. Olyan csomagolástechnikai feladatról is beszámoltak, ahol a

csomagolás ellenőrző gép működési környezete miatt nem biztosítható, hogy a vizsgálandó csomag képéhez hasonló eredményező idegen tárgy nem kerülhet a látómezőbe, részleges takarással is lehet számolni, továbbá nem küszöbölhető ki a külső fény, az árnyék és a csillogás torzító hatása sem, sőt a tárgytávolság is változhat a képvételek alatt [8], [9], [10]. Ha ilyen körülmények között kell algoritmussal az osztályba sorolást elvégezni, a gépi tanulás eszköztárát használják. Ebből az is következik, hogy az ilyen rendszerfejlesztés legalább két fő fázisból áll. Az egyik a tanítás, a másik – ezt követő – a betanított rendszer működtetése. A tanító fázis a gyakorlati tapasztalatok szerint időigényes. A szakirodalom [2], [6] és a tapasztalat szerint a jól teljesítő megoldásokban lényeges szerepet játszik az előzetes ismeret. A gépi tanulás eszköztárából itt két irányzatot említünk. Az egyikben az algoritmusfejlesztési fázisban hagyományosan döntési fát „növesztenek” az adott tárgyterületre vonatkozó szakértői tudás bevonásával. Olyan módszereket is kidolgoztak, amivel a döntési fák a tanító adatrendszerből, algoritmussal hozhatók létre. A másik esetben szakértő bevonásával tanító adatrendszert készítenek. A tanítóval történő, más néven felügyelt tanulás esetében a tanító adatrendszer <prototípus pont | osztálycímke> párokból áll. A tanító nélküli, más néven nem felügyelt tanulás esete az, amikor az osztálycímke nem áll rendelkezésre. Ez utóbbi esetet klaszterezésnek is szokás nevezni.

A továbbiakban három, a csomagolástechnikáról szóló közleményekben szereplő, a felügyelt tanuláshoz tartozó, mesterséges neurális hálózat alapú algoritmust mutatunk be röviden. Ezek a következők: többrétegű perceptron hálózat (MLP, Multi-Layer Perceptron), szupport vektor gép (SVM, Support Vector Machine), konvolúciós neurális hálózat (CNN, Convolutional Neural Network).

Az említett algoritmusok bár lényegesen különböznek egymástól, mégis két dolog közös bennük. Az egyik az, hogy a sokdimenziós, valós elemű vektorok terében működnek. A prototípuspont pont lehet maga a kép, vagy olyan képleíró, ami a képnek az osztályozás szempontjából lényeges jellemzőit tartalmazza számszerű formában. A képleíró létrehozását lényegkiemelésnek (feature extraction) nevezzük. A másik a tanuló rendszer fejlesztésének módja, ami a gyakorlatban ciklikus jellegű, numerikus kísérletezés. Ennek érdekében a tanító adatrendszert általában három részre osztják, ezek a tanító, tesztelő és validáló diszjunkt részhalmazok. A ciklikus tevékenység egy ciklusa a tanítás/tesztelés és az algoritmusfejlesztő „elfogadható”/”nem elfogadható” döntése. Ez addig ismétlődik, amíg a betanított rendszer döntése elfogadható pontosságú lesz. Végül a validálással meghatározott döntési pontosság lesz az irányadó a betanított rendszer működtetési fázisában [6].

3.1. MLP

Az MLP az ipari képosztályozás céljára közvetlenül is használható, és a jelen cikk következő pontjában bemutatott CNN végső részhálózata is valamely MLP variáns.

A többrétegű perceptron hálózat előre rögzített elrendezésbe – rétegekbe – szervezett feldolgozó egységekből áll. A feldolgozó egységet a műszaki szaknyelvben szokás (mesterséges) neuronnak, az ezekből álló számítási struktúrát pedig (mesterséges) neurális hálózatnak nevezni. A feldolgozó egységet jellemzi a súlyvektora és az aktivációs függvénye. A feldolgozó egységben az első művelet skaláris szorzás, melynek eredményéből az aktivációs függvénnyel áll elő a kimeneti érték. A bemeneti rétegben nincs számítás, ide maga a kép (vagy a képleíró) csatlakozik. Ezt követi egy vagy több rejtett réteg. Ezek aktivációs függvénye nemlineáris, általában a logisztikus- vagy a tangens hiperbolikus függvény. A hálózat kimeneti rétegében lévő feldolgozó egységek aktivációs függvénye az osztályba sorolás esetében szintén nemlineáris, de eltérhet a rejtett rétegetől. A rétegek számát, a rétegeken belüli feldolgozó egységek számát, a feldolgozó egységek aktivációs függvényeit a hálózat definiálásakor rögzíteni szükséges.

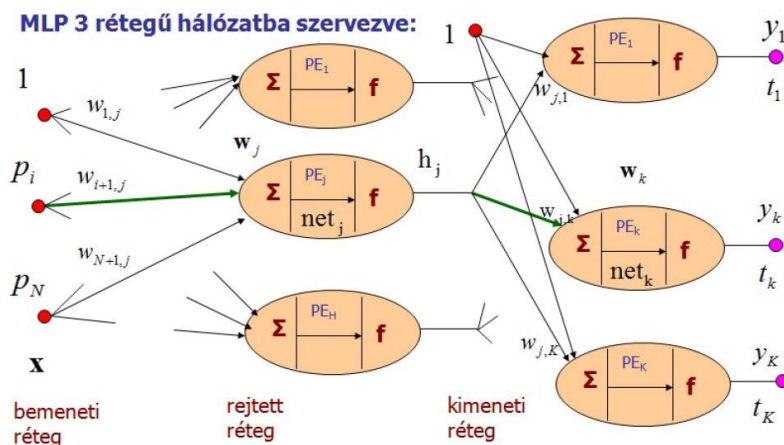
Az egyes feldolgozó egységek súlyvektorait kell a tanító adatrendszer ismeretében meghatározni ezek után. Ez lehetséges, mert a neurális hálózathoz tartozik egy jósági függvény is. Ez sokváltozós függvény, melyben a tanító adatokon kívül szerepelnek a súlyvektorok is. A jósági függvény extrémumának meghatározása alapján adódik a hálózat tanítási eljárása. Bár többféle jósági függvényt is kidolgoztak, egyiknek sincs globális extrémuma, tehát nincs egyetlen, „legjobb” súlyvektor-készlet. Vannak viszont olyan tanító algoritmusok, amelyek lépésről-lépésre visznek egyre közelebb a jósági függvény valamely lokális extrémumához.

Az egy rejtett rétegű MLP hálózat felépítése az 1. ábrán látható. Itt a PE név a feldolgozó egységre, $w_{..}$ a súlyvektor komponensre, a Σ jel a skaláris szorzatra, az f pedig az aktivációs

függvényre utal. Az MLP-t előrecsatolt hálózatnak is nevezik, mert nincs sem rétegen belüli, sem rétegek közötti visszacsatolás.

Fentebb említettük, hogy a tanító adatrendszer <prototípus pont | osztálycímke> párokból áll. A prototípus-pont N dimenziós, valós elemű vektor, az 1. ábrán a p betűvel utalunk rá. A tanításhoz az ω_k osztályba tartozó prototípuspont címkejéből meg kell alkotni a véges dimenziós, valós elemű t célérték-vektort, melynek dimenziója az osztálycímkek kódolásától függ. Gyakori, hogy a dimenzió az osztályok száma (az 1. ábrán K , $k = 1, 2, \dots, K$), és a célértékvektor egyfajta indikátor: az ω_k osztály esetén a k -adik komponense 1, a többi 0. Az MLP tanításához a prototípus pontból létre kell még hozni az x tanítópontot, amihez a p prototípuspontot ki kell bővíteni az 1 konstanssal (ld. az ábrán). Ezzel az x tanítópont is és a rejtett rétegbeli feldolgozó egységek w súlyvektora is $N+1$ dimenziós lesz. Így biztosítható (a rejtett rétegen) az MLP feldolgozó egységei számára szükséges ún. eltolás-tag (bias, vagy hagyományosabb megközelítésben szinaptikus küszöbérték). Fontos, hogy ez általánosan is igaz: ilyen eltolás-tagja az MLP minden feldolgozó egységének van (ld. az ábrán a kimeneti rétegnél).

Tanításkor a tanító adatrendszerből képzett $\langle x | t \rangle$ vektorpárokból rendre „előveszünk” egy aktuális x tanítópontot a hozzá tartozó t célértékvektorral. Az előrehaladó számításokkal kapható az aktuális y kimeneti vektor, így képezhető az $e = t - y$ különbségvektor. (Az 1. ábrán az $y_1, t_1, \dots, y_k, t_k, \dots, y_K, t_K$ komponens-párokat tüntettük fel.) Ezen különbségvektor, vagy hiba alapján módosíthatók a kimeneti rétegbeli feldolgozó egységek súlyvektorai. Annak ellenére, hogy a rejtett réteg feldolgozó egységeinek h_j kimeneteihez nincsenek célértékek, mégis módosíthatók ezek súlyvektorai is, mivel a kimeneti rétegbeli hibákból számíthatók eltérések a rejtett réteg feldolgozó egységeihez is. Ha több rejtett réteg van, visszafelé, a bemeneti réteg felé kell a számításokat fokozatosan elvégezni. A részleteket illetően a [6] szakirodalomra utalunk.



1. ábra. Egy rejtett rétegű MLP hálózat

Megemlítendő még, hogy nemcsak egyetlen rejtett réteg lehet, hanem több is. Ha "elég sok" található benne, akkor mély neurális hálózatnak nevezik (DNN, Deep Neural Network), egyébként sekélynek (shallow). A szakirodalom nem egységes abban, hogy mennyi az "elég sok". Manapság rendelkezésre állnak fejlesztő eszközök a mély neurális hálózatok tanítására. Ugyanis konstruálható olyan MLP hálózat, amely a tanító adatpárokkal megadott tetszőleges nemlineáris leképezés megtanulására képes (az MLP ún. univerzális approximátor). Ennek alapja az a matematikai tétel, amelyet részletesen ismertet Haykin [6] (Universal Approximation Theorem, p.167. Eq. (4.88)).

3.2. SVM

Az előző pontban ismertetett fogalmak lehetővé teszik, hogy a szupport vektor gép (SVM, Support Vector Machine) lényegét röviden bemutathassuk.

A szemléletesség kedvéért képzeljük el, hogy az MLP-t megfosztjuk a rejtett rétegeitől, és csak a bemeneti és a kimeneti réteg marad. Ha még az utóbbi aktivációs függvénye lineáris, akkor az így keletkező hálózatról kimutatható, hogy a tanító adatpontokat szétválasztó hipersíkot képes a tanító adatpontokból előállítani („megtanulni”). Az SVM kétsztályos osztályba sorolási feladat esetén

optimális hipersíkot állít elő a tanító adatokból (lineárisan nem szétválasztható feladat esetében először nemlineáris dimenziónövelő transzformációt kell a tanító adatpontokon végrehajtani). Az SVM fontos tulajdonsága viszont, hogy kvadratikus programozási feladatra vezet, aminek – szemben az MLP-ével – létezik globálisan optimális megoldása. Sőt, a tanító adatok számánál kevesebb vektor vesz részt a működtetési fázis számításaiban (ezeket nevezik szupport vektoroknak). A számításokat kimerítő részletességgel tartalmazza [2], [6]. Valódi ipari képosztályozási feladatok esetén a tanítási fázis számítási igénye nagy.

3.3. CNN

A konvolúciós neurális hálózatot (CNN, Convolutional Neural Network) eredetileg kézzel írt irányítószoftverek felismerésére dolgozták ki az 1980-as évek második felében. Jelenleg elterjedt a képosztályozásban. Felépítését tekintve konvolúciós és méretcsökkentő rétegek követik egymást, végül egy MLP kimeneti rétegen olvasható le a döntés. A mély CNN esetében a konvolúciós és méretcsökkentő rétegekből több van. A konvolúciós rétegben mátrixok lineáris konvolúciójának kiszámításával lényegében a képen lévő helyi sajátosságokat "derítik fel", majd az $y = \max(0, x)$ alakú függvényt alkalmazzák a mátrix elemire. A méretcsökkentő művelet 2-vel való decimáció. Az utolsó konvolúciós rétegben kapott mátrixokat egyetlen vektorra alakítják és ez lesz az MLP bemenete (az MLP szintén lehet mély). Az MLP kimeneti rétegének vektorából dekódolhatók a tanító adatrendszerből származó osztálycímek.

A képosztályozók fejlesztéséhez léteznek sok képből álló, általános célú, címkézett képi adatbázisok. Ilyen például a COCO (Common Objects in COntext). A CNN esetében elérhetők ezzel előre tanított variánsok, amiket az adott feladathoz felépített további tanító adatrendszer birtokában lehet "testre szabni". Megjegyzendő, hogy az intelligens kamera gyártók kínálatában szerepel jól definiált ipari feladatra előtanított CNN is.

4. Csomagolástechnikai alkalmazások

4.1. SVM alkalmazása csomagológépben

Wu és Lu csomagológépeken alkalmazott, SVM-mel működő képosztályozót ismertetnek [7]. A feladat szappandobozokon előforduló sérülések meglétének észrevétele, és ennek megfelelő beavatkozás végrehajtása. A sérülések három kategóriába sorolhatók voltak: a) gyűrődés, b) ponthibák, c) foltok. A képosztályozót három SVM-mel valósították meg, mindegyik hibatípushoz tartozik egy. Először felépítették a tanító adatrendszert, ami sérüléstípusonként pozitív és negatív példákat mutató képekből állt. A tanító adatrendszer teljes tárigénye kb. 130 GB volt, a képosztályozó tanítása 204 órát vett igénybe (ez több, mint 1 hét). A cikkben a sérülés helyes felismerésére a 90%..99% intervallumot adták meg. Fontos adat még a működtetett rendszernél a válaszidő, ami 700 ms..1500 ms közé esett (kis válaszidő és nagy pontosság jellemezte az egyetlen hibatípus esetét).

Bahaghghat, Akbari és Xina közleményében a feladat buborékfóliás (bliszteres) csomagolású gyógyszerkészítményeknél a még nyitott dobozban lévő bliszterek számlálása és az esetleges hiány megállapítása volt [8]. Beszámolójuk szerint ebben a feladatban a legnagyobb nehézséget a változékony megvilágítás és a szállítószalag képvétel közbeni mozgása okozza. A bliszter anyaga ugyanis többféle műanyag is lehet, a fedőréteg pedig főként alumínium fólia. Négy osztályt definiáltak aszerint, hogy mennyi a dobozban lévő bliszterek száma (0, 1, 2 vagy 3), mindegyikhez kb. 1000 darab színes, 500x700 pixeles képből álló tanító adatrendszert készítettek. Az SVM-mel a helyes felismerés pontossága 86% volt.

4.2. CNN alkalmazása csomagológépben

Laura és társai csomagológépben alkalmazott, CNN-nel működő képosztályozót ismertetnek [9]. A feladat egységtrakomány szerkezeti épségének megállapítása képosztályozó rendszerrel. Az egységtrakomány szabályosan elhelyezkedő kisebb szállítási egységekből áll. A rendszerrel szemben támasztott követelmény volt, hogy egy vagy több (egymásra pakolt) egységtrakomány esetében is működjön, mégpedig egyetlen RGB színes kép alapján. A cikkben ismertetett képosztályozó működéséhez a következő feltételek előzetes biztosítása szükséges: a) az

egységalakomány nem sérült, b) két teljes oldallap látszik a képen, c) nincs takarás, d) biztosan „felfelé” áll (a kamerakép függőleges határvonalával párhuzamos élek láthatók). A megoldáshoz konvolúciós neurális hálózatokat használtak. Külön erre a feladatra kidolgozott tanító adatrendszert is készítettek. A teljes feladatot három részfeladatra bontották, mindegyik megoldásához külön CNN-t használtak az alábbiak szerint: 1) a szállítmány szegmentálása 2) a két oldallap 3) a rakományban lévő szállítási egységek szegmentálása. A szállítmány szegmentálásához a COCO adatbázison előtanított CNN-ből indultak ki. A helyes felismerés pontossága 84% volt.

Aisyah, Nainggolan, Simanjuntak és Lubis mély konvolúciós neurális hálózat alkalmazásáról számolnak be [10]. A feladat karakterfelismerés csomagolt élelmiszereken okostelefon kameraképe alapján. A megoldáshoz öt konvolúciós rétegből és három, egymást követő, teljesen összekötött hálózattól álló CNN-t használtak. A cikk szerint a feldolgozó egységek száma összesen mintegy 800 ezer volt. Összesen 100 csomagot vizsgáltak, 93% helyes felismerési arányt értek el.

5. Összegzés

A cikkben bemutattuk a moduláris csomagológépben is alkalmazható ipari képfeldolgozó rendszert és ismertettünk néhány, az ipari képfeldolgozásban bevált eljárást. A bizonytalan körülmények közötti csomagolástechnikai képosztályozási feladatban alkalmazott tanuló eljárások közül az SVM és CNN alapú rendszereket mutattuk be. Munkánk folytatásaképpen jelenleg egy képosztályozó mérőcella megvalósításán dolgozunk, mely a moduláris csomagológéphez illeszthető. A cikkben ismertetett képfeldolgozó módszerek és csomagolástechnikai alkalmazások alapján a csomagolásra vonatkozó „megfelelt”/”nem felelt meg” típusú döntést mintaillesztéssel tervezzük megvalósítani, amihez X-Y irányú pozicionálással és megfelelő megvilágítással alkalmas képvevő mérőhelyet hozunk létre a mérőcellában.

Köszönetnyilvánítás

A szerzők köszönetet mondanak a projektben résztvevő intézmények - Nádor Rendszerház Kft., Controlsoft Automatika Szolgáltató Kft., Neumann János Egyetem GAMF Műszaki és Informatikai Kar - kollégáinak. Köszönettel tartozunk a kutatás támogatásáért, amely az "Ipar 4.0 moduláris felépítésű ipari csomagológép fejlesztése integrált adatelemzéssel és mesterséges intelligenciára épülő optimalizálással, hibaelemzéssel 2020-1.1.2-PIACI-KFI-2020-00062" pályázat keretében valósult meg. A projekt a Magyar Állam és az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával, a Széchenyi 2020 program keretében valósul meg.

Irodalomjegyzék

- [1] Álló G., Hegedűs Gy. Cs., Kelemen D., Szabó J.: A digitális képfeldolgozás alapproblémái. Akadémiai Kiadó, Budapest, 1989.
- [2] M. Sonka, V. Hlavac, R. Boyle: Image Processing, Analysis and Machine Vision. Fourth Edition, Cengage Learning, 2015.
- [3] R. C. Gonzalez, R. E. Woods: Digital Image Processing. Fourth Edition. Pearson, 2018.
- [4] M. Rudorfer, J. Kruger J.: Industrial Image Processing Applications as Orchestration of Web Services. Procedia CIRP 76 (2018) 144–148.
DOI: 10.1016/j.procir.2018.01.030
- [5] P. Pietrzkiwicz: Image Analysis Techniques for Industrial Inspection Systems. <https://www.adaptive-vision.com/download/mvg.pdf> [letöltve 2022. 09. 30.]
- [6] S. Haykin.: Neural Networks and Learning Machines. Third Edition. Pearson 2009.
- [7] Yu Wu and Yanjie Lu: An intelligent machine vision system for detecting surface defects on packing boxes based on support vector machine. Measurement and Control. 2019, Vol. 52(7-8) 1102–1110
DOI: 10.1177/0020294019858175
- [8] M. Bahaghighat, L. Akbari, and Q. Xina: Machine Learning-Based Approach for Counting Blister Cards Within Drug Packages. IEEE Access, Vol. 7. 2019, pp. 83785-83796
DOI:10.1109/ACCESS.2019.2924445
- [9] Laura Dörr, Felix Brandt, Martin Pouls and Alexander Naumann: An Image Processing Pipeline for Automated Packaging Structure Recognition. FZI Research Center for Information Technology. arXiv 29 Sep 2020
DOI: 10.48550/arXiv.2009.13824
- [10] S. Aisyah, F. S. Nainggolan, M. Simanjuntak, E. A. Lubis: Food Packaging Search Application From Text Image In Android With Deep Convolutional Neural Network (DCNN) Method. IOP Conf. Series: Journal of Physics:

Conf. Series 1230 (2019) 012078
DOI:10.1088/1742-6596/1230/1/012078