

# Nonkontakt polimerszortírozó rendszer az újrahasznosításban

## Contact-free polymer sorting system used in recycling

SIPOS Bence<sup>1</sup>, GYÖRGY Levente<sup>2</sup>

Budapesti Műszaki és Gazdaságtudományi Egyetem MSc<sup>1</sup> hallgató, illetve BSc<sup>2</sup> hallgató,  
1111 Budapest, Műegyetem rkp. 3; tel.: +36 1 463-1111  
Központi fax: +36 1 463-1110, www.bme.hu

### Kivonat

*2017-re a világ teljes polimer előállítás meghaladta a 348 millió tonnát, amelynek jelentős része rövid időn belül hulladékká válik. A műanyag hulladék szortírozásának automatizálása nem megoldott, jelentős emberi beavatkozást igényel. A manuális válogatással szortírozott hulladék csak alacsony százalékban használható fel új termékek gyártására a polimerek degradálódása és az eltérő összetétel miatt. Az elmúlt két évben egy nonkontakt anyagvizsgáló módszert dolgoztunk ki, mely nagy pontossággal képes a polimerek osztályozására. Ehhez egy általunk épített spektroszkópot használtunk [1], amely a hagyományos kalibrált spektroszkópokhoz képest jelentősen lecsökkenti a vizsgálat költségét.*

**Kulcsszavak:** polimer, reflexió, spektrum, spektroszkópia, gépi tanulás

### Abstract

*By 2017 the total polymer production in the world was over 348 million tonnes, majority of it will soon become waste. Automation of the sorting of plastic waste is an unsolved problem, therefore requires significant human intervention. Manually sorted waste can only be used in a small percentage to produce new products due to polymer degradation and different composition. Over the past two years, we have developed a contact-free material test method that is able to classify polymers with high accuracy. We used a custom-made spectroscope [1], which significantly reduces the cost of the examination compared to conventional calibrated spectroscopes.*

## 1. BEVEZETÉS


A polimerek vizsgálatára számos lehetőség van, kémiai, fizikai és optikai tulajdonságok vizsgálatával válik lehetővé az egyes anyagok megkülönböztetése. A kémiai és fizikai vizsgálatok pontosak, viszont jóval lassabban végezhető az optikai vizsgálatokhoz képest. Az anyagok spektroszkópiája nem új terület, viszont csak mostanra vált reálissá, hogy akár valós idejű feldolgozást teyenek lehetővé egy futószalag mellett. A mi módszerünk gyors és pontos, miközben a többi spektroszkópiai vizsgálattal ellentétben nem igényel kalibrálást, ami kiválóan alkalmassá teszi a hulladék válogatási feladatokra.

Az alábbiakban a fő hangsúlyt a kiértékelő algoritmusok, illetve az azokkal végzett tesztheink eredményeinek bemutatására helyezzük. Méréseink során végig tekintettel voltunk azok gyakorlatba való átültethetőségére, a zavaró körülmények esetleges jelenlétére.

## 2. SPEKTROSKÓPIAI HÁTTÉR

A spektroszkópiát laborkörülmények között már évtizedek óta használják polimerek megkülönböztetésére és vizsgálatára, viszont ezek sokszor igen költséges és sok előkészítést igénylő mérések, melyek használata nem lenne gazdaságos. A beható vizsgálatokhoz a legtöbb esetben Raman-spektroszkópot használnak, ami igen költséges optikai elemeket tartalmaz, ezek kiváltása nehéz és a kiváltáshoz használt módszer a mérés hosszát jelentősen megnöveli.

A járhatóbb út a gyors polimer reflexió vizsgálatra infravörös spektroszkópia használta. Működéséhez egy monokromátort használ, ami a fényforrás összetett fényét hullámhossz szerint térben szétbontja és ezen a szétbontott tartományon mérjük a fény intenzitását. Az összetett fénynyaláb útjába helyezett anyag az öt jellemző energiaszinteken elnyel, így azon hullámhossz komponensek hiányoznak majd a szétválasztott spektrumból. Ezt követően a fényforrásból származó eredeti fény és az abszorpció utáni fény arányát meg tudjuk jeleníteni egy grafikonon. Mivel itt csak az arány jelenik meg, így nincs szükség drága és érzékeny referencia fényforrásokra. Az egyetlen követelmény, hogy a forrás az összes vizsgált hullámhosszon sugározzon, tehát lehetőleg folytonos legyen a spektruma.



1. ábra A PET infravörös-spektruma, jelölve a különböző kötésekre jellemző frekvenciák [2]

A kötésekre jellemző energiaszintek elnyelését vizsgálva az anyag összetétele meghatározható, viszont ehhez a rendszer kalibrálása elengedhetetlen. Korábban az abszorpciós görbe kiértékelése a legtöbb esetben csak ezen kötésre jellemző pontok mérését jelenti, sokszor nem használnak összetettebb kiértékelő módszereket, annak ellenére sem, hogy azok sokkal érzékeltlenebbek a zajra. Ezzel szemben mi kvantitatív kiértékelés helyett csak a görbe jellegét vizsgáljuk.

### 3. ADATFELDOLGOZÁSI HÁTTÉR

Több módszert is megvizsgáltunk, azzal kapcsolatban, hogy milyen biztonsággal képes az osztályozási feladatot elvégezni és ezt milyen gyorsan teszi.

A K-legközelebbi szomszéd (KNN) módszer sok dimenziós adatok osztályozásra használható és a csoportosítást egy általunk definiált távolság függvényvel végzi. A módszer működési elve, hogy az egyes vektorok pontjainak valamely mérték szerinti távolságát számolja és összegzi. Ezt követően a legközelebbi  $n$  mintát ehhez köti, így akár két minta segítségével is el tudjuk dönteni, hogy a harmadik minta hova tartozik, melyikre hasonlít jobban. Magas dimenziószám esetén a számítása nehéz és erőforrás-igényes, így érdemes egy becslő módszert használni a távolságok meghatározásához (Approximate Nearest Neighbor Search, röviden ANNS). [3]

One-shot Hausdorf módszer előnyösebb sok esetben az egyszerű Euklideszi távolságot használó K-legközelebbi szomszédhoz képest, mindezt úgy, hogy a távolság metrika két pontsor egymáshoz viszonyított minimális távolságot nézni. Tehát a vizsgált pontsor minden pontjához megkeresi a referencia pontok közül a legközelebbit és ezeknek a távolságoknak a minimumát keresi és a minimumhoz tartozó referenciával azonos csoportba sorolja a mintát. A zaj hatása sokkal kisebb az ANNS-hez képest, viszont a távolság átlagolás miatt ennek a módszernek is van hátránya. [4]

A gépi tanuló módszerek közül LSTM-et (Long-Short-Term Memory) és az 1D konvolúciót vizsgáltuk. Az LSTM háló alapja az LSTM cella, amit három kapura szoktak bontani: input/bemeneti kapu, output/kimeneti kapu és a forget/elfelejtő kapu. Az egyes kapuk működése a nevéből egészen jól kikövetkeztethető. A bemeneti kapu felel a cellába érkező adatok fogadásáért, a kimeneti pedig a cellában lévő adatok alapján egy aktivációs függvényen keresztül szolgáltatja a kimenetet. A forget/elfelejtő kapu az, ami igazán érdekes, ez felel azért, hogy mely adatok maradjanak bent a cellában,

ezzel befolyásolva a kimenetet. Emellett ez a kapu felelős a memóriajellegért, tehát ezzel képes hosszabb távon figyelembe venni korábbi eseményeket. Az 1D konvolúció az LSTM-hez hasonló tulajdonságokkal bír, viszont sokkal jobban paralellizálható, így gyorsabb futást tesz lehetővé. [5-6]

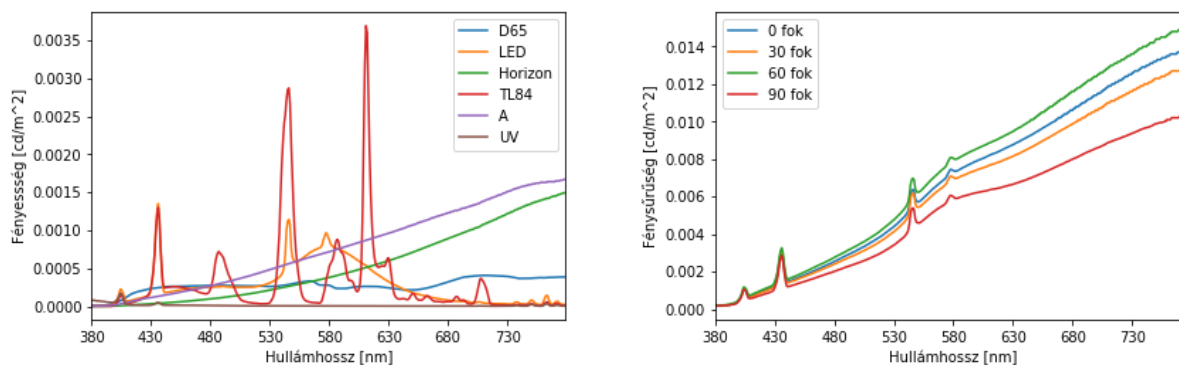
Egyre fejlettebb kevés adatot használó módszerek jelennek meg, főleg a képfeldolgozás területén, melyek jól lehet használni ehhez a feladathoz is. A nagy hátrányuk, hogy jóval összetettebbek és nem minden esetben nyújtanak jelentős pontosság javulást a tradicionális módszerekhez képest. Az egyik ilyen a DeepMind által fejlesztett MANN architektúra a másik pedig a Siamase háló. Utóbbi páronkénti vizsgálaton alapul innen ered a neve is. Méréseink során nem volt kimutatható használatukkal javulás az LSTM-hez képest. [7]

Ezek mellett lehetséges még dimenzió redukciós módszereket alkalmazni. Ezek magas dimenziós adatsorokhoz rendelnek egy alacsonyabb dimenziójú pontot, lehetőleg 2-3 dimenzióban a könnyebb megjelenítés miatt. Az átalakítás minden esetben információ veszteség következik be, de kifinomult módszerek alkalmazásával az anyagában eltérő mintákat szeretnénk a levetített térbe minél nagyobb távolságra eltolni. Ilyen módszer a főkomponens-analízis (PCA), a t-SNE és az UMAP. [8,9]

A főkomponens-analízis során az adatokra illesztünk egy hiperellipszoidot és ennek a két legnagyobb főtengelye lesz a síkba vetítés két merőleges x-y tengelye. Az t-SNE dimenzió redukció két lépésben történik, az első - számunkra érdekesebb - lépés során létrehoz egy valószínűségi eloszlást véletlenszerűen kiválasztott pontpárok segítségével. Ezt követően a második lépésben létrehoz egy alacsonyabb dimenziójú eloszlást, és a két eloszlás Kullback-Leibler divergenciáját minimalizálja. Az UMAP működése igen érdekes, manifold learning segítségével dolgozik, de a háttérben működő matematika még különlegesebbé teszi. Riemann-geometriát és algebrai topológiát használ.

## 4. VIZSGÁLATAINK

A vizsgálatokhoz FDM (fused filament fabrication) technológiával 3D nyomtatással hoztunk létre politejsav, PET-G (módosított polietilén-tereftalát) és ABS (akrilnitril-butadién-sztirol) anyagokból. Ezeket használtuk a reflexió méréseinkhez egy kontrollált környezetben. A legnagyobb hatással a mérésekre a környezeti fény volt, ennek hatására több mérést végeztünk. A környezeti fény spektruma és erőssége is nagy hatással volt az olvasás pontosságára, ezeket az 2. ábrán ábrázoltuk.



2. ábra A vizsgált fényforrások és a megvilágítás

A következő változó a referencia megvilágítás és a polimer felület normálisa által meghatározott szög volt, itt arra a következtésre jutottunk, hogy 30 fokos szög esetén kapjuk a legjobb eredményeket, mivel ekkor a felület csillogása már nem jelentős, viszont a koszinusz törvényből meghatározott fényesség érték még megfelelően magas.

## 5. KIÉRTÉKELÉS MÓDSZEREINEK ÖSSZEHAISONLÍTÁSA

A vizsgált kiértékelő módszereknek a normalizált spektrumokat adtuk be, és ezek osztályozási pontosságát vizsgáltuk (1. táblázat).

*A kiértékelő módszerek összehasonlítása*

1. táblázat

Szempont	Hausdorff	KNN	1D konvolúció	LSTM	Siamese	Mann
Pontosság	megfelelő	megfelelő	megfelelő	megfelelő	megfelelő	magas
Erőforrás igény	alacsony	alacsony	közepes	közepes	magas	magas
Futási idő	alacsony	alacsony	közepes	közepes	magas	magas
Tanítási idő	nincs	nincs	közepes	közepes	magas	magas
Könnyen imp	igen	igen	nem	igen	igen	nem

A korábban bemutatott módszereket saját adatainkkal teszteltük és a stabilitásuk vizsgálata céljából változó mennyiségű zajt is kevertünk ezekhez a spektrumokhoz. Az optimális megoldásnak az LSTM háló alkalmazása bizonyult, mivel gyorsan fut és mégis képes nagy pontosságot elérni.

A főkomponens analízis nem volt képes a pontokat polimer szerint szeparálni. Az UMAP (Uniform Manifold Approximation and Projection) esetén már az ABS elvált a többi mintától, de a legjobb eredményt a t-SNE (t-distributed stochastic neighbor embedding) alkalmazásával sikerült elérni. A dimenzió redukciót követően már sok klaszterező eljárás közül válogathatunk, mi a legegyszerűbbet, a k-közép módszerét választottuk.

## 6. ÖSSZEZÉS

A rendszer a kiértékelés elvéből adódóan nem igényel kalibrált spektrométert ezért a szortírozás a korábbinál jóval alacsonyabb áron megvalósítható. A fentieket összegezve kijelenthetjük, hogy a mérési eljárás megfelelhet a polimerszortírozás feladata által állított valós időben történő szortírozás követelményeinek.

## IRODALOMJEGYZÉK

- [1] SIPOS, B., GYÖRGY, L. (2019). Összehasonlító vizsgálat spektroszkóppal, one-shot technikával. In I. Barabás (Ed.), OGÉT 2019 XXVII. Nemzetközi Gépészeti Konferencia [27th International Conference on Mechanical Engineering] (pp. 480-483). Nagyvárad: Erdélyi Magyar Műszaki Tudományos Társaság - EMT
- [2] JEL-SAFTAWY, A. A., et al. Electron beam induced surface modifications of PET film. *Radiation Physics and Chemistry*, 2014, 102: 96-102.
- [3] MUJA, Marius; LOWE, David G. Fast approximate nearest neighbors with automatic algorithm configuration. *VISAPP* (1), 2009, 2.331-340: 2.
- [4] HUTTENLOCHER, Daniel P.; KLANDERMAN, Gregory A.; RUCKLIDGE, William J. Comparing images using the Hausdorff distance. *IEEE Transactions on pattern analysis and machine intelligence*, 1993, 15.9: 850-863
- [5] GERS, Felix A., SCHMIDHUBER, Jürgen, et CUMMINS, Fred. Learning to forget: Continual prediction with LSTM. 1999.
- [6] KIRANYAZ, Serkan, et al. 1D convolutional neural networks and applications: A survey. *arXiv preprint arXiv:1905.03554*, 2019.
- [7] KOCH, Gregory; ZEMEL, Richard; SALAKHUTDINOV, Ruslan. Siamese neural networks for one-shot image recognition. In: *ICML deep learning workshop*. 2015.
- [8] MCINNES, Leland; HEALY, John; MELVILLE, James. Umap: Uniform manifold approximation and projection for dimension reduction. *arXiv preprint arXiv:1802.03426*, 2018.
- [9] MAATEN, Laurens van der; HINTON, Geoffrey. Visualizing data using t-SNE. *Journal of machine learning research*, 2008, 9.Nov: 2579-2605.