

ZASTOSOWANIE WYBRANEJ TECHNIKI EKSPLOKACJI DANYCH W PRZEMYSŁE POLIGRAFICZNYM

Krzysztof EJSMONT, Krzysztof KRYSTOSIAK, Jan LIPIAK

Streszczenie: W pracy przedstawiono znaczenie eksploracji danych w procesie pozyskiwania wiedzy, omówiono główne metody wchodzące w skład tej dziedziny nauki oraz opisano szerzej jedną z nich – sztuczne sieci neuronowe. Zaprezentowano również podstawowe problemy do rozwiązania których wykorzystuje się metody eksploracji danych. Artykuł przedstawia przykład praktycznego zastosowania wybranej metody (SSN) w procesie produkcji etykiet termokurczliwych, a także prezentuje system zbierania danych produkcyjnych na przykładzie firmy poligraficznej.

Słowa kluczowe: pozyskiwanie wiedzy, eksploracja danych, sztuczna inteligencja, sztuczne sieci neuronowe, etykiety termokurczliwe.

1. Wstęp

Wraz z rozwojem technologii informacyjnych, które w dzisiejszych czasach towarzyszą ludziom niemal w każdej dziedzinie życia, powstały metody oraz narzędzia, które uprościły i umożliwiły gromadzenie oraz przechowywanie ogromnych ilości danych. Równocześnie coraz niższe stają się koszty tworzenia, gromadzenia, zarządzania oraz przechowania elektronicznej informacji, co niejako powoduje, że firmy coraz chętniej przeznaczają większe środki finansowe na inwestycje związane ze zbieraniem danych, ich przechowywaniem oraz uzyskiwaniem z nich określonych korzyści [1].

Powołując się na raport *“The Digital Universe in 2020: Big Data, Bigger Digital Shadows, and Biggest Growth in the Far East”* można oszacować, że w latach 2012-2020 ilość cyfrowej informacji podwajać się będzie dwukrotnie co każde dwa lata, podczas gdy wzrost inwestycji w infrastrukturę pozyskiwania informacji wyniesie około 40%. Wynikiem tego będzie dziesięciokrotny spadek ceny 1 GB danych (z 2 dolarów w 2012 roku do 20 centów w 2020 roku) [2]. Wśród niewyobrażalnie dużej ilości danych, gromadzonych na co dzień w firmach produkcyjnych, znajduje się wiedza, potencjalnie użyteczna z punktu widzenia licznych procesów przez nie realizowanych (produkcja, logistyka, zarządzanie itp.). Jednakże trzeba mieć świadomość, że tylko część z tych danych jak na razie może zostać przeanalizowana, zrozumiana oraz wykorzystana. Dla przykładu w 2020 roku, jedynie 33% zgromadzonych cyfrowych danych będzie posiadać potencjalnie użyteczne informacje, co i tak stanowi znaczący wzrost w porównaniu z 23% (643 exabajtów) w roku 2012 [2]. Zarysowuje się tu bardzo wyraźny problem polegający zarówno na umiejętności zbierania i przechowywania jedynie tych danych, które mogą być użyteczne z punktu widzenia przedsiębiorstwa oraz tego za pomocą jakich metod i narzędzi można pozyskiwać z nich wartościowe dla firmy informacje. Jest to wyzwanie szczególnie dla firm działających w sektorach dynamicznie się rozwijających, w których generowane są ogromne ilości nowych danych. Sektorem takim jest bez wątpienia sektor poligrafii.

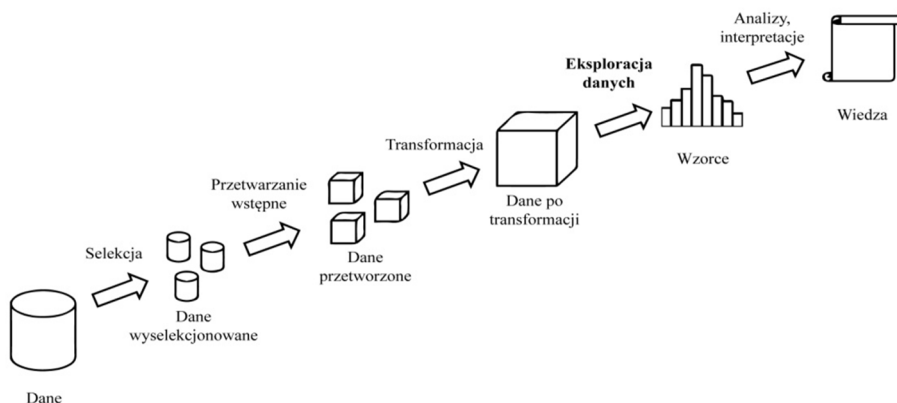
W przyszłości, efektywne wykorzystanie zgromadzonych danych możliwe będzie głównie dzięki wykorzystaniu zaawansowanych metod analizy oraz interpretacji danych, poszukując wzorców, korelacji w danych, łącząc dane produkcyjne z logistycznymi itp.

2. Pozyskiwanie wiedzy, a eksploracja danych

Ogromna ilość zgromadzonych danych oraz potencjalne możliwości ich nowego wykorzystania doprowadziły do wzrostu zapotrzebowania na metody oraz narzędzia, które będą w stanie te dane odpowiednio przetwarzać oraz pozyskiwać z nich użyteczne informacje. Pod koniec lat 80-tych ubiegłego wieku powstało pojęcie odkrywania wiedzy (ang. *knowledge discovery*) rozumiane jako skomplikowany proces polegający na odkrywaniu nowych, potencjalnie użytecznych i finalnie zrozumiałych wzorców z danych [3].

W oparciu o tę definicję, na podstawie zgromadzonych w bazie danych rekordów można próbować wydobyć pewne pojęcia i wyrażenia, które będą posiadać zdolność opisu danych, przedstawiać ich strukturę oraz odzwierciedlać zależności w nich występujące. Dodatkowo mechanizmy generowania tych wzorców powinny cechować się zdolnością odkrywania z danych nowej wiedzy, potencjalnie użytecznej dla eksperta bądź też systemu informatycznego analizującego wyniki, a same wzorce (lub wnioski uzyskane na ich podstawie) powinny być przedstawione końcowemu użytkownikowi (np. pracownikowi produkcyjnemu) w prostej i zrozumiałej formie.

Pozyskiwanie wiedzy jest procesem złożonym i wieloetapowym – począwszy od selekcji zebranych danych, wstępnego ich przetwarzania, transformacji i wyboru najlepszego algorytmu do analizy danego problemu, a skończywszy na jej interpretacji i prezentacji użytkownikowi. Wybór właściwego algorytmu oraz jego zastosowanie do rozwiązania konkretnego problemu określane jest często terminem eksploracji danych (ang. *data mining*). W wielu opracowaniach poświęconych eksploracji danych wymienia się między innymi narzędzia takie jak: sztuczne sieci neuronowe, analiza regresji, drzewa decyzyjne, algorytmy genetyczne oraz algorytmy indukcji reguł decyzyjnych. Zależności między procesem eksploracji danych, a pozostałymi elementami procesu pozyskiwania wiedzy, przedstawiono na rysunku 1.



Rys. 1. Etapy procesu pozyskiwania wiedzy
Źródło: Opracowanie własne na podstawie [4]

Eksploracja danych stanowi najistotniejszy element w procesie pozyskiwania wiedzy. Ponieważ pozostałe etapy tego procesu są albo zagadnieniami rutynowymi, w porównaniu do samego zagadnienia eksploracji danych (np. selekcja danych), albo są nierozłącznie związane z samą eksploracją danych, dlatego w wielu opracowaniach dochodzi do

zrównania, lub też utożsamienia pozyskiwania wiedzy z eksploracją danych, poprzez pominięcie wyszczególniania pozostałych etapów [5].

3. Metody eksploracji danych

Eksploracja danych jako dziedzina nauki ma już dość stabilną pozycję, pomimo tego, że jest to stosunkowo młoda gałąź nauki. Sam termin powstał z końcem lat 80-tych ubiegłego stulecia. Eksploracja danych uformowała się w kilku różnych etapach, w wyniku ewolucji takich dziedzin nauki jak: klasyczna statystyka, sztuczna inteligencja oraz maszynowe uczenie [5]. Statystyka od samego początku była dziedziną mającą najistotniejszy wkład w analizy biznesowe (ang. *business intelligence*). Mimo tego, że w dzisiejszych czasach same tylko metody statystyczne nie są wystarczające, aby analizować ogromne zbiory danych, w dalszym ciągu stanowią one podstawę większości metod i narzędzi poszukujących wzorców oraz zależności występujących w danych. Metody sztucznej inteligencji to najogólniej rzecz biorąc metody, które starają się naśladować procesy myślenia ludzi oraz ludzkiej inteligencji w procesie analizy danych. Kolejną dziedziną, która dała podstawy do rozwoju metod eksploracji danych to maszynowe uczenie – dział nauki który zajmuje się konstrukcją systemów mających zdolności uczenia się na podstawie analizy danych [6].

Odkrywanie wiedzy z danych przedstawia eksplorację danych jako dobrze zorganizowaną metodologię, silnie powiązaną z menadżerami, decydentami i tymi, którzy zajmują się wdrożeniem wyników. Automatyzacja nie zastąpi udziału człowieka. Ludzie muszą być efektywnie zaangażowani podczas każdego etapu eksploracji danych. Zamiast dopasowywać ludzi do eksploracji danych, należy zastanowić się, jak można zaprojektować eksplorację danych jako bardzo ludzki proces rozwiązywania problemów. Główne narzędzia eksploracji danych tworzą metody i algorytmy obliczeniowe związane z rozwiązaniem podstawowych zagadnień tworzących zręby tej dziedziny [7, 8].

Sześć podstawowych problemów, w których rozwiązanie zaangażowane są metody eksploracji danych to [1, 3]:

- klasyfikacja – umiejętność systematycznego podziału nowych, nieznanych obiektów na pewne grupy lub klasy, wykonywana według określonej zasady, najczęściej poprzez generalizowanie posiadanej wcześniej informacji o cechach znanych obiektów i ich przyporządkowaniu do grup. Przykłady najpopularniejszych metod wykorzystywanych w klasyfikacji to: naiwny klasyfikator bayesowski, drzewa decyzyjne, sieci neuronowe, reguły decyzyjne, maszyny wektorów wspierających,
- regresja – poszukiwanie funkcji pozwalającej badać związek pomiędzy wielkościami danych i przewidywać na tej podstawie rzeczywiste wartości analizowanych zmiennych minimalizując błędy między wartością rzeczywistą a przewidywaną,
- grupowanie (z ang. *data clustering*) – zadanie grupowania elementów we względnie jednorodne klasy, które charakteryzują się pewnym podobieństwem wyrażonym przy pomocy funkcji (metryki) prawdopodobieństwa na podstawie cech opisujących elementy, bez wcześniejszej informacji o istnieniu takiego podobieństwa. Podstawowy podział algorytmów grupowania to: grupowanie hierarchiczne, algorytmy oparte o metody k-średnich, metody analizujące rozkład danych, metody gęstościowe oraz metody grupowania rozmytego,
- podsumowywanie (ang. *summarization*) – zbiór metod, które umożliwiają konkretny i znacznie łatwiejszy w interpretacji opis danych, często poprzez wizualizację czy automatyczne generowanie raportów,

- poszukiwanie reguł asocjacyjnych (modelowanie zależności) – poszukiwanie zależności pomiędzy poszczególnymi cechami opisującymi analizowane obiekty (np. poszukiwanie zależności pomiędzy kupnem komputera i rodzajem nabywanego oprogramowania). Podstawowe metody indukcji reguł asocjacyjnych to algorytm Apriori, Eclat oraz FP-growth,
- detekcja zmian, anomalii i odchyłeń – identyfikacja nieszablonowych wzorców występujących w danych, które mogą okazać się z jakiegoś powodu interesujące lub wskazywać na istnienie błędów wymagających dalszego rozpoznania i analizy.


Jedną z wielu metod eksploracji danych są sztuczne sieci neuronowe (z ang. *artificial neural networks*). Oprócz nich wyróżniamy takie techniki jak metody statystyczne, metody uczenia maszynowego, drzewa decyzyjne, czy logika rozmyta [9]. Sztuczne sieci neuronowe należą również do elementów sztucznej inteligencji [10]. Dwa główne rodzaje zastosowań sztucznych sieci neuronowych to klasyfikacja i regresja [11], aczkolwiek standardowym obszarem zastosowań jest całokształt zagadnień związanych z rozpoznawaniem obrazów [9]. Zagadnienia te obejmują nie tylko analizę obrazów, lecz także ich klasyfikację, grupowanie i przetwarzanie. Obecnie algorytmy sieci neuronowych znalazły zastosowanie w wielu innych dziedzinach i obszarach zastosowań, z pośród których wymienić należy takie jak [9]:

- analiza – problemów produkcyjnych, spektralna, sygnałów radarowych,
- diagnostyka – układów elektronicznych, maszyn,
- dobieranie – pracowników, materiałów wejściowych,
- optymalizacja – działalności handlowej, ruchów robota,
- planowanie remontów maszyn,
- prognozowanie – notowań giełdowych, cen, sprzedaży,
- sterowanie – procesów przemysłowych, pojazdów, robotów.

Modele sieci neuronowych są dużo bardziej prymitywne niż ich pierwowzór – czyli biologiczny układ nerwowy, pomimo to pozwalają na modelowanie zjawisk oraz procesów słabo ustrukturyzowanych i zalgorytmizowanych. Dają one możliwość zbudowania efektywnie działającego modelu bez określania natury związków między zmiennymi. Posiadają również umiejętność adaptacji i samorealizacji nabytą w procesie uczenia sieci [7, 9, 11].

Zastosowanie sieci jest szczególnie efektywne tam, gdzie potrzeba jasnych i precyzyjnych wyników przy skomplikowanych obliczeniach. Stanowią one przyczynek do stworzenia sztucznej inteligencji pozwalającej na zarządzanie przedsiębiorstwem z minimalnym udziałem czynnika ludzkiego [12]. Sieci neuronowe mogą być sklasyfikowane na podstawie kilku wyróżniających je cech, do których należą: typ sygnału wejściowego, budowa sieci i sposób ich uczenia. Sygnał wejściowy może być sygnałem binarnym lub ciągłym [9]. Do pierwszego typu należą takie typy sieci jak: sieć Hopfielda, sieć Hamminga, czy też sieć ART1. Perceptron i sieć Kohonena są przedstawicielami drugiego typu sieci [9].

Analizując struktury sieci neuronowych, można wyróżnić trzy główne rodzaje: sieci jednokierunkowe, rekurencyjne i komórkowe [9, 11]. Cechą charakterystyczną dla sieci jednokierunkowych jest to, że sygnał przebiega od neuronu warstwy niższej do neuronu warstwy wyższej, ponadto w sieciach takich nie występują połączenia między neuronami w tej samej warstwie, ani też połączenia od neuronów warstwy wyższej do niższej [11]. Przykładem takiej sieci neuronowej jest perceptron. Rysunek 2 przedstawia sieć typu MLP, czyli perceptron wielowarstwowy (z ang. *Multi Layer Perceptron*). Jest to najczęściej używany typ sieci [11].



Rys. 2. Schemat sztucznej sieci neuronowej typu MLP
 Źródło: Opracowanie własne na podstawie [11]

Sztuczna sieć neuronowa typu MLP składa się z trzech głównych warstw: wejściowej, ukrytej i wyjściowej. Neurony warstwy wejściowej przetwarzają pierwotne sygnały na wejściu do sieci. W warstwie ukrytej może być dowolna ilość neuronów, jak również samych warstw ukrytych, aczkolwiek badania wykazały, iż zbyt duża liczba neuronów w warstwie ukrytej może niekorzystnie wpływać na zdolności sieci do generalizacji. Ilość neuronów w warstwie wyjściowej odpowiada ilości zmiennych zależnych badanego problemu [11].

Opisując budowę modelu sztucznej sieci neuronowej należy wspomnieć o budowie pojedynczego neuronu. Na wejściu do neuronu docierają sygnały – wartości wejściowe, które pochodzą od neuronów warstwy poprzedniej, albo też są to wartości pierwotne – w przypadku gdy są to neurony warstwy wejściowej. Sygnały wejściowe posiadają swoje wagi, czyli wartości odpowiadające efektywności danej synapsy w neuronie. Każdy neuron posiada też tzw. wartość progową, która musi zostać przekroczona, w celu zadziałania neuronu. Sam neuron składa się z dwóch bloków: sumowania i aktywacji. Blok sumowania oblicza ważoną sumę wejść, tj. sumę wartości sygnałów wejściowych przemnożoną przez współczynniki wagowe, co można określić poniższym wzorem [11]:

$$s = \sum_{i=1}^n w_i x_i \quad (1)$$

gdzie: s – ważona suma wejść,
 w_i – współczynnik wagowy,
 x_i – wartość sygnału wejściowego.

Blok aktywacji oblicza wartość wyjściową neuronu i w najprostszej postaci jest nią funkcja liniowa $y = f(s)$. Poza funkcją liniową wyróżniamy następujące funkcje aktywacji:

- sigmoidalna,
- tangensoidalna,
- gaussowska.

Powyżej wymienione funkcje aktywacji neuronu określane są niekiedy jako s-kształtne, gdyż są to funkcje aktywacji dostarczające sygnały o wartościach zmieniających się w sposób ciągły. Progowa funkcja aktywacji jest stosowana bardzo rzadko. W celu określenia prawidłowych wartości parametrów sieci, czyli wag i struktury sieci, jest realizowany proces uczenia sieci. Uczenie sieci polega na wykorzystaniu dostępnych zestawów danych, tzw. danych uczących, które ilustrują przebieg badanych zjawisk dla wybranych obiektów. Dla sieci typu MLP jest realizowany proces uczenia z nauczycielem, tzn. zbiory danych zawierają

zarówno wartości zmiennych wejściowych jak również wartości zmiennych wyjściowych. Podczas procesu uczenia sieci wprowadzane są wartości dostępnych zestawów danych na wejścia do sieci i obserwowany jest wynik obliczeń sieci. Uzyskana w ten sposób wartość jest porównywana z rzeczywistą wartością zbioru uczącego. Jeżeli porównywane wartości nie są równe, wówczas wagi zmieniają się w taki sposób, aby odpowiedź sieci była jak najbliższa wartości rzeczywistej zbioru uczącego. Proces uczenia wymaga wielokrotnego porównywania wzorców uczących i odpowiadających im modyfikacji wag. Każda taka modyfikacja nazywana jest epoką, cyklem uczenia lub też iteracją. Proces uczenia sieci składa się wielu epok [11].

4. Identyfikacja produktu w przemyśle poligraficznym

W przemyśle poligraficznym powstaje wiele różnorodnych produktów, jednym z nich są etykiety. Etykieta jest to wyrób z folii lub papieru umieszczony bezpośrednio na produkcie lub jego opakowaniu w celu zidentyfikowania lub określenia jego zawartości. Obecnie etykiety to coś więcej niż tylko informacja – służą także działaniom marketingowym, reklamując produkt przez przyciągnięcie uwagi konsumentów. Ich zadaniem jest także świadczenie o jakości wyrobu i wzmacnianie jego marki [6].

Proces produkcji etykiet odbywa się głównie metodą druku fleksograficznego na samoprzylepnych podłożach z folii i papieru. Technologia ta oparta jest na użyciu wypukłej formy drukowej, która nadaje się do zadruku podłoży używanych do tej produkcji [13,14]. Druk etykiet odbywa się na wstędze, która następnie może być rozcinana i przekazywana klientowi w formie mniejszych rolek do dalszego wykorzystania przy produkcji opakowań.

Jednym z najprężniej rozwijających się rodzajów etykiet, również na naszym rynku, są etykiety termokurczliwe. Etykiety termokurczliwe (z ang. *shrink sleeve labels*), są to etykiety powstające w wyniku zadruku oraz formowania rękawa z folii, który pod wpływem określonej temperatury dla danego materiału ulega skurczeniu, przylegając ściśle do powierzchni docelowej. Etykiety tego typu powstają najczęściej w wyniku zadruku fleksograficznego [15]. Celowe zatem wydaje się znalezienie optymalnego systemu pozwalającego zbierać dane uzyskiwane podczas procesu produkcji etykiet oraz użycie właściwych technik eksploracji do uzyskania najlepszych parametrów wejściowych i wyjściowych.

5. Budowa systemu zbierania danych produkcyjnych w celu wyboru optymalnej techniki drukowania

Produkcja etykiet samoprzylepnych jest bardzo złożona, w ciągu jednego miesiąca produkuje się kilkaset różnych wzorów, niektóre zlecenia są krótkie, inne długie. Problemem jest dokładne obliczenie zyskowności każdego zlecenia produkcyjnego. Wraz z tym problemem istnieje problem właściwej oceny pracowników, określenie normatywów pracy, opracowanie wskaźników zdolności produkcyjnych OEE (z ang. *Overall Equipment Effectiveness*), itp. W procesie produkcji etykiet główną jednostką jest metr bieżący oraz rolka, gdyż jest to druk rolkowy – z rolki na rolkę – pomimo tego, że klienci zamawiają nakład w sztukach, kilogramach lub metrach sześciennych.

Dlatego też niezmiernie istotny jest dobór optymalnej techniki druku etykiet z uwzględnieniem zdefiniowanych głównych czynników determinujących dla danego zlecenia produkcyjnego z wykorzystaniem technik eksploracji danych, w celu opracowania reguł postępowania. Produkcja fleksograficzna jest bardzo złożona, wręcz usługowa, toteż celowe

są wszelkie techniki optymalizacji procesu, zwłaszcza, iż wiele parametrów wyznaczanych jest eksperymentalnie. Pytanie, jakie należy zadać brzmi: kiedy zastosować druk fleksograficzny, a kiedy lepiej opłaca się zadruk techniką cyfrową (z ang. *inkjet*)?

Miesięcznie, w typowym przedsiębiorstwie poligraficznym produkuje się kilkaset zleceń produkcyjnych, z czego każde może różnić się diametralnie od innych: wielkością nakładu (wyrażoną w metrach bieżących), ilością kolorów, stopniem trudności, itp. Problemem z jakim się spotykamy jest chociażby dokładne obliczenie rentowności każdego zlecenia produkcyjnego. Ponadto kolejnym problemem jest określenie normatywów pracy, zważywszy na znaczną zmienność produkcji etykiet.

Celem budowy systemu zbierania danych będzie wychwycenie, które zlecenia produkcyjne nie są efektywne tj. opłacalne ekonomicznie, przy danej technice drukowania. Opracowane reguły postępowania, na bazie zebranych danych historycznych z wykorzystaniem znanych czynników determinujących, pozwolą na oszacowanie jaka technika drukowania będzie bardziej ekonomiczna dla danego zlecenia. Pozwoli to przedsiębiorstwu na optymalne wykorzystanie posiadanego parku maszynowego i technik zadruku, co przełoży się na lepszą efektywność ekonomiczną. Uważa się, iż zastosowanie narzędzi statystycznych w celu opracowania metody doboru optymalnej techniki drukowania może przyczynić się do ograniczenia strat z powodu niewłaściwego doboru techniki drukowania do danego zlecenia, a tym samym umożliwi uzyskanie wymiernych efektów technicznych, ekonomicznych i organizacyjnych dla danego przedsiębiorstwa poligraficznego.

Czynniki determinujące, o których mowa powyżej w teście, to między innymi:

- Technologiczność zlecenia (pierwszy parametr – warunek konieczny: możliwość drukowania danego zlecenia obiema technikami, jeżeli tak – można rozpatrywać poniższe determinanty);
- Nakład brutto zlecenia [mb];
- Rodzaj materiału [A, B, C, ...];
- Ilość rolek użyta do druku zlecenia [szt.];
- Rodzaj farb [np. standard, *low migration*, ...];
- Ilość kolorów [szt.];
- Warstwa lakieru [0;1];
- Ilość nałożonych farb [g/m²];
- Uszlachetnianie w linii (*coldstamping/hotstamping*) [0;1];
- Stopień trudności druku [np. trójstopniowa skala: 1-3];
- Jakość przejść tonalnych (drobne rastry) [0;1].

Podane powyżej zestawienie determinantów wyboru danej techniki drukowania nie jest listą zamkniętą, gdyż mogą występować inne czynniki determinujące, mające mniej lub bardziej istotny wpływ na ekonomiczność wyboru techniki drukowania, które nie są znane w danym momencie. Pozostaje to w kwestii dalszych badań naukowych. Kolejnym krokiem będzie zbieranie danych produkcyjnych z przedsiębiorstwie poligraficznym, wykonanych w obu wspomnianych powyżej technikach drukowania, z uwzględnieniem czynników determinujących, wymienionych powyżej oraz opracowanie wstępnych modeli efektywności ekonomicznej produkowanych zleceń. Dane, o których mowa powyżej będą zbierane w kilku przedsiębiorstwach poligraficznych z rejonu województwa mazowieckiego, przez okres ok. jednego roku, w celu zebrania jak największej ilości danych. Przyjmuje się wykorzystanie metod statystycznych oraz technik eksploracji danych w pracy nad zebranymi danymi.

6. Predykcja parametrów nawijania rękawa etykiet termokurczliwych z użyciem Sztucznej Sieci Neuronowej

Głównymi etapami procesu wytwarzania etykiet termokurczliwych są cztery etapy typowo produkcyjne, w wyniku których otrzymuje się wyrób gotowy w postaci rękawa etykiet nawiniętego na roli. Tymi etapami są: druk, brzegowanie – cięcie, formowanie rękawa, inspekcja. Wspólną cechą w/w etapów procesu produkcyjnego jest nawijanie z roli na rolę, stąd też procesy fleksograficzne nazywane są często rolowymi (z ang. *reel to reel processing*), ponieważ na wejściu do każdego etapu surowiec lub półprodukt z poprzedniego etapu jest nawinięty w postaci roli. W celu zapewnienia odpowiedniej jakości etykiet termokurczliwych oraz bezproblemowego przebiegu całego procesu produkcji, bardzo istotny jest proces nawijania na każdym etapie oraz jakość nawoju. Ogólna problematyka jakości etykiet termokurczliwych została przedstawiona w pracy [15] oraz w pracy [16] w kontekście znaczenia metod wytwarzania. Mówiąc o poziomie jakości, należy zaznaczyć, iż istotnym parametrem mającym znaczący wpływ na jakość nawoju są początkowe parametry naciągów, które utrzymują odpowiednie naprężenie wstęgi lub rękawa podczas nawijania, zarówno na odwijanej rolce – nazywanej odwijakiem (z ang. *unwind* – odwijając, rozwijając, *unwinder* – odwijak), jak również na nawijanej rolce (z ang. *rewind* – nawijając, zwiżając, *rewinder* – nawijak) – nazywanej nawijakiem.

Głównym parametrem charakteryzującym jakość nawoju jest brak stwierdzonych wad, zarówno w procesie produkcji jak też u finalnego odbiorcy, takich jak:

- sklejenie warstw rękawa ze sobą,
- teleskopowanie,
- efekt *blocking*,
- rozciągnięcie folii,
- zagniecenia,
- uszkodzenia rękawa na zaprasowaniu,
- zniszczenie nawoju.

Tematyka jakości nawoju, jest powszechnie znana na zachodzie, w angielskojęzycznych pozycjach literaturowych z tej dziedziny przewija się termin *web handling* [17, 18], co oznacza w wolnym tłumaczeniu radzenie sobie z nawijaniem wstęgi, lub inaczej nawijanie wstęgi z maksymalną wydajnością i z minimalną stratą. Pytanie jakie należy zadać mówiąc o jakości nawoju konfekcjonowanego wyrobu brzmi: jakie parametry początkowe naciągów są odpowiednie? Jest to problem stanowiący obiekt badań naukowych i są różne metody określania parametrów naciągów, niemniej jednak jest to wiedza bazująca na stałym doświadczeniu i eksperymentowaniu, gdyż wiele jest zmiennych mających wpływ na jakość nawoju.

W praktyce produkcyjnej w większości dużych przedsiębiorstwach poligraficznych są gromadzone dane, zapisy dotyczące parametrów procesu. Wydobyć z nich informacji w postaci opracowanych modeli reguł i zasad postępowania jest przedmiotem interdyscyplinarnej dziedziny nauki jaką jest eksploracja danych (z ang. *data mining*), która wykorzystuje metody statystyczne, czy sztucznej inteligencji, jak np. sztuczne sieci neuronowe, drzewa decyzyjne, systemy ekspertowe i inne. Efektem tych działań będzie poprawa jakości wyrobu i procesu oraz obniżenie kosztów wytwarzania.

W celu opracowania skutecznej metody do sterowania jakością nawijanych etykiet zastosowano sztuczną sieć neuronową. Sieci neuronowe najczęściej stosowane są do rozwiązywania problemów klasyfikacji bądź regresji, w tym wypadku będzie to problem typowo regresyjny. Przeprowadzono badania pilotowe na zebranych danych historycznych

procesu konfekcjonowania etykiet termokurczliwych na etapie formowania rękawa, które zawierają następujące zmienne sterujące:

- x_1 – szerokość materiału [mm]
- x_2 – grubość materiału [μm]
- x_3 – rodzaj materiału [X, Y, Z, ...]
- x_4 – prędkość nawijania [m/min]
- x_5 – producent materiału [A, B, C, ...]

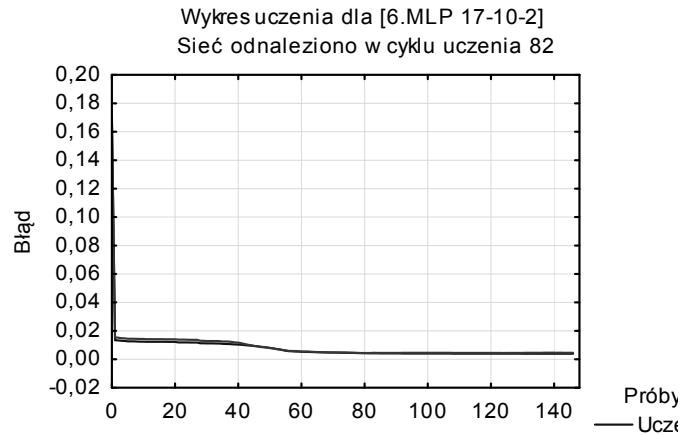
Powyższe zmienne są danymi wejściowymi do modelu sztucznej sieci neuronowej, natomiast wyjściem sieci będą dwie zmienne zależne – nastawy początkowe naciągów odwijaka i nawijaka:

- y_1 – naciąg odwijak [N]
- y_2 – naciąg nawijak [N]

Jak łatwo zauważyć, przedstawione dane wejściowe należą zarówno do typu danych ciągłych i dyskretnych. Nie stanowi to problemu, gdyż na wejściu sztucznej sieci neuronowej mogą być różne typy danych. Wymienione powyżej zmienne wejściowe odnoszą się tylko do niektórych parametrów mających wpływ na efekt w postaci prawidłowo nawiniętej roli etykiet termokurczliwych, dlatego opracowany model nie będzie idealny, gdyż w procesie mogą występować pewne zakłócenia. Również stosowane materiały mogą być różnej jakości i pewne cechy mogą oddziaływać na jakość nawijania, aczkolwiek niniejsze badania stawiają za cel udowodnić celowość zastosowania tej metody. Zadaniem modelu SSN jest odnalezienie zależności między danymi wejściowymi i wyjściowymi.

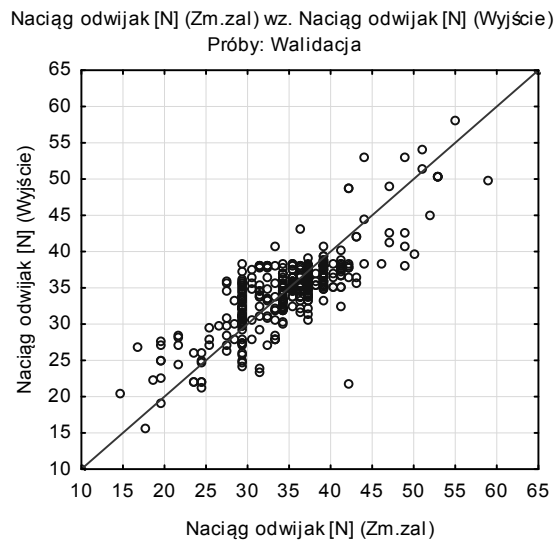
W celu opracowania modelu sieci użyto pakietu oprogramowania *Statistica* Automatyczne Sieci Neuronowe SANN(z ang. *Statistica Automated Neural Networks*). Przetestowano wiele wariantów modeli sieci, finalnie wybrano sieć MLP 17-10-2, co oznacza że jest to sieć typu: perceptron wielowarstwowy składający się z 17 neuronów w warstwie wejściowej (dwie zmienne dyskretne zostały rozdzielone na pojedyncze neurony), 10 neuronów w warstwie ukrytej i 2 neuronów w warstwie wyjściowej – czyli poszukiwanych optymalnych nastaw naciągów odwijaka i nawijaka. Sieć została odnaleziona w 82 cyklu uczenia (Rys. 3).

Opracowany w ten sposób model sztucznej sieci neuronowej posiada współczynniki korelacji zmiennych zależnych z wyjściem sieci na poziomie 0,81 dla początkowych nastaw naciągu odwijaka i 0,86 dla początkowych nastaw naciągu nawijaka. Korelacje te zostały zbadane na próbie walidacyjnej. W procesie pracy na danych uczących następuje podział wszystkich danych na trzy grupy: ucząca, testująca i walidacyjna, gdzie program *Statistica* losowo przydziela dane do trzech grup, natomiast ich wielkość jest domyślnie podzielona na 70% dla grupy uczącej, i po 15% dla grup testującej i walidującej [10]. To oznacza, że opracowany model SSN na grupie uczącej jest testowany na danych testowych, które nie brały udziału w opracowaniu modelu, natomiast walidacja modelu SSN odbywa się na danych walidacyjnych. Współczynnik korelacji zmiennej zależnej z wyjściem sieci neuronowej jest jednym z wielu mierników jakości opracowanego modelu sieci. Im wyższy współczynnik, tym dokładniejszy jest opracowany model [10]. Oczywiście bardzo wiele zależy też od jakości zebranych danych. Istnieje wiele metod i technik przygotowywania, czyszczenia, a nawet uzupełniania brakujących danych, nie są one jednak przedmiotem niniejszego opracowania.

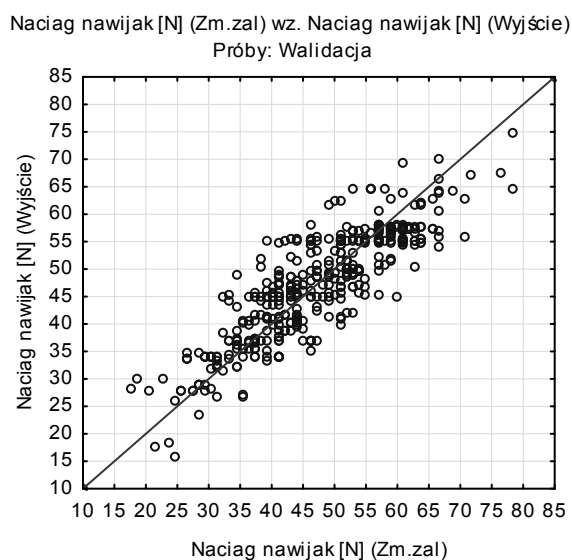


Rys. 3. Wykres uczenia sztucznej sieci neuronowej
Źródło: Opracowanie własne

Analizując wykresy korelacji zarówno dla naciągu odwijaka (Rys. 4), jak też naciągu nawijaka (Rys. 5), można zauważyć pewne wartości zbioru odbiegające od linii korelacji, co można tłumaczyć w dwojnasób: albo jakość danych nie była zadowalająca (zważywszy, że są to dane historyczne), albo istnieją zmienne, czynniki i zależności, które nie zostały uwzględnione w sporządzonym modelu SSN.



Rys. 4. Wykres korelacji sztucznej sieci neuronowej dla naciągu odwijaka
Źródło: Opracowanie własne



Rys. 5. Wykres korelacji sztucznej sieci neuronowej dla naciągu nawijaka
Źródło: Opracowanie własne

Uzyskane współczynniki korelacji oscylujące w granicach 0,8 jak na dane przemysłowe są dość dobre, toteż uzyskany model można uznać za wystarczający do poprawnego działania – sztuczna sieć neuronowa odnalazła zależności występujące w procesie. W tym miejscu należy nadmienić, iż model ten został opracowany na danych historycznych, które były możliwe do uzyskania. Kierunkiem dalszych badań związanych z eksploracją danych procesu konfekcjonowania etykiet termokurczliwych w przedsiębiorstwie powinno być zebranie danych z obecnego procesu wraz z wieloma innymi istotnymi parametrami, które w obecnym modelu zostały pominięte ze względu na ich brak, takimi jak np.: poziom zadruku farb na folii, obecność dodatkowej warstwy kleju *hot-melt*, średnica nawijanej roli oraz wiele innych.

7. Podsumowanie i wnioski

Wraz z rozwojem narzędzi oraz technologii służących do gromadzenia danych, coraz więcej firm i przedsiębiorstw (np. z branży poligraficznej) zaczęło wykorzystywać metody eksploracji danych w swojej codziennej działalności.

Opracowany model sztucznej sieci neuronowej może zostać wykorzystany do predykcji początkowych nastaw naciągów odwijaka i nawijaka – parametrów bardzo istotnych w procesie konfekcjonowania etykiet termokurczliwych, mających niebagatelny wpływ na jakość nawoju. Raz opracowaną sieć można wykorzystywać stale, do predykcji naciągów każdego nowego zlecenia produkcyjnego, a należy pamiętać, że w przemyśle poligraficznym każdego dnia jest realizowanych kilka, a nawet kilkanaście nowych zleceń, o zgoła odmiennej charakterystyce (szerokość i grubość wstęgi lub rękawa, rodzaj materiału, ilość farb, warstwa *hot-melt* i inne). Sztuczna sieć neuronowa potrafi perfekcyjnie odnaleźć skomplikowane nawet zależności i interakcje występujące w procesie, a co za tym idzie jej zastosowanie może być efektywne i wymierne dla jakości procesu i wyrobu gotowego.

Literatura

1. Gruca A.: Raport Obserwatorium ICT: Eksploracja Danych. Park Naukowo-Technologiczny „Technopark Gliwice”, Gliwice 2013.
2. Gantz J., Reinsel D.: The Digital Universe in 2020: Big Data, Bigger Digital Shadows, and Biggest Growth in the Far East. Sponsored by EMC Corporation, 2012.
3. Fayyad U., Piatetsky-Shapiro G., Smyth P.: From data mining to knowledge discovery in databases. AI Magazine, Vol. 17, 1996.
4. Han J., Kamber M., Pei J.: Data Mining: Concepts and Techniques. Morgan Kaufmann, San Francisco 2011.
5. Mazur D.: Metody grupowania i ich implementacja do eksploracji danych postaci symbolicznej. Rozprawa doktorska, Zabrze 2005.
6. Witryna internetowa: <http://www.infosystems.pl/strona-glowna> - Infosystems.
7. Larose T. D.: Odkrywanie wiedzy z danych - wprowadzenie do eksploracji danych. Wydawnictwo PWN, Warszawa 2006.
8. Osowski S.: Metody i narzędzia eksploracji danych. Wydawnictwo BTC, Legionowo 2013.
9. Knosala R. i Zespół: Zastosowania metod sztucznej inteligencji w inżynierii produkcji. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
10. Witryna internetowa: <http://www.statsoft.pl/> - StatSoft.
11. Tadeusiewicz R.: Sieci Neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993.
12. Werpachowski W.: Podstawy zarządzania w przedsiębiorstwie. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2011.
13. Czech G.: Technologia fleksograficzna. Zagadnienia standaryzacji. Centralny Ośrodek Badawczo-Rozwojowy Przemysłu Poligraficznego, Warszawa 1993.
14. Kipphan H.: Handbook of print media. Technologies and Production Methods. Springer, Germany 2001.
15. Ejsmont K., Krystosiak K.: Metody wytwarzania etykiet termokurczliwych. „Ekonomika i Organizacja Przedsiębiorstw” nr 12/2014, Wyd. ORGMASZ, Warszawa 2014.
16. Krystosiak K., Werpachowski W.: Doskonalenie poziomu jakości opakowań spełniających wymagania klienta. „Ekonomika i Organizacja Przedsiębiorstw” nr 11/2013, Wyd. ORGMASZ, Warszawa 2013.
17. Witryna internetowa: <http://www.convertingquarterly.com/> - Web Processing & Finishing Technologies.
18. Witryna internetowa: <http://www.pffc-online.com/> - Paper, Film & Foil Converter.

Mgr inż. Krzysztof EJSMONT
Mgr inż. Krzysztof KRYSTOSIAK
Mgr inż. Jan LIPIAK
Instytut Organizacji Systemów Produkcyjnych
Wydział Inżynierii Produkcji, Politechnika Warszawska
02-524 Warszawa, ul. Narbutta 86
tel./fax: (22) 234-81-23, (22) 849-01-85, (22) 849-93-90
e-mail: krzysztof.ejsmont@wp.pl
k.krystosiak@wip.pw.pl
janlipiak@etigraf.pl