

Možnosti využitia neurónových sietí v celulózovo-papierenskom priemysle

Využitie neurónových sietí pri zostavovaní predikčného modelu riadenia kvality výroby má v papierenskom priemysle svoje opodstatnenie vzhľadom na kontinuálny výrobný proces, pri ktorom sú vstupné charakteristiky trvalo udržiavané v predpísaných medziach a zároveň treba nepretržite kontrolovať kvalitu výstupu. Predikčný model sa vytvára „samoučiacim sa“ procesom z histórie časovo od seba závislých dát získaných metódami modernej štatistiky.

Softvérový produkt na predikciu kvalitatívnych charakteristík vyrábaného papiera umožňuje predikovať tuhosť papiera v smere stroja (machine direction) a z neho aj tuhosť v priečnom smere, porozitu alebo index formácie na základe vstupných parametrov, ako sú obsah plniva, množstvo náteru, ťah navinovača, efluxný pomer, rozdiel rýchlosti látky a sita papierenského stroja, zanáška dlhovláknitej buničiny v papieri apod. Hlavným cieľom je zvýšenie kvality papiera a tým aj konkurencieschopnosti výrobku na trhu. Predikčný model využíva metódy štatistickej analýzy a umelých neurónových sietí.



Využitie neurónových sietí

Neurónové siete sú schopné „naučiť sa“ dynamiku procesov výroby papiera priamo z historických dát (Moody 1989, Hartman 1990). Vo svojej podstate sú to nelineárne algoritmy schopné modelovať viacrozmerné systémy, ktoré majú jednoduché a uniformné používateľské rozhranie. Neurónové siete sú nápomocné pri vývoji statických a dynamických modelov a osvedčili sa pri kontinuálnych aj diskontinuálnych procesoch. Výhodou neurónových sietí je rovnaký algoritmus vhodný pre viacero rozličných systémov. S danými systémami pracujú lepšie ako tradičné expertné systémy riadené podľa pravidiel, keďže tie sa len ťažko rozoznávajú alebo ide o veľký počet pravidiel. Samozrejmosťou neurónových sietí je úspora práce využívaním výpočtovej techniky a nízka náročnosť na kvalifikáciu personálu. Ďalšou výhodou vzhľadom na výrobné podmienky je aj pomerná necitlivosť na hluk.

Proces tréningu neurónových sietí má dva stupne: budovanie modelu a optimalizáciu riadenia. Prvý stupeň je rovnocenný s klasickou predikciou problému. Predpovedané výstupy sú priebežne dodávané hodnoty z modelu neurónovej siete. Predpokladá sa niekoľko vstupov $x_1(t)$, $x_2(t)$, ..., $x_n(t)$. Ďalej sa predpokladá viacero výstupných

parametrov $a_1(t)$, ..., $a_k(t)$. Neurónová sieť sa naučí dynamiku procesov z historických dát a je tak schopná predpovedať výstupy $y_1(t)$, ..., $y_r(t)$, ktoré sú porovnateľné a veľmi blízke skutočným výstupom $a_1(t)$, ..., $a_k(t)$.

Na testovanie správneho fungovania predikčnej schémy slúžia niektoré historické dáta, ktoré model trénujú. Keď model ukončí učenie sa z daného súboru dát, testovací systém použije zostávajúce dáta na zistenie toho, do akej miery dokáže model pracovať s neznámymi dátami. Testová relatívna chyba je celková chyba pre kompletný postup cez testovacie dáta. Čím je chyba menšia, tým je model lepší. Nulová relatívna chyba znamená, že model predpovedá dáta bezchybne. Relatívna chyba vyššia ako 1,0 znamená, že takýto model je horší ako model, ktorý konštantne predpovedá strednú hodnotu dát. R^2 je štandardná chyba merania pri lineárnej regresii. Rovnica (1) ukazuje vzťah medzi relatívnou chybou a R^2 :

$$R^2 = 1 - (\text{relatívna chyba})^2 \quad (1)$$

Ak sú výsledky tréningovej a testovej chyby blízke a nízke a model predpovedá testované dáta presne, po ukončení tréningu nastáva zovšeobecnenie modelu. Táto metóda bola aplikovaná aj pri systémoch prania nebielenej buničiny (Rudd 1991) a rafinácii termicko-mechanickej buničiny (Kooi 1992).

Neurónová sieť využíva veľmi jednoduché funkcie v skrytých vrstvách (typické sú napr. sigmoidálne krivky), pričom ich však kombinuje v rámci viacvrstvovo usporiadanej štruktúry. Pomocou neurónovej siete možno aproximovať akúkoľvek funkciu.

Štruktúra neurónovej siete a počet adaptačných krokov

Návrh vhodnej štruktúry neurónovej siete je zložitý numerický problém, preto bolo zavedené obmedzenie len na neurónové siete s jednou vrstvou skrytých neurónov (Kvasnička 1997). Hlavným kritériom optimálneho návrhu neurónovej siete bude optimálnosť jej klasifikačnej schopnosti a realizácia tohto návrhu sa bude vykonávať súbežne s určením optimálneho počtu adaptačných krokov. Nasledujúce účelové funkcie reprezentujú tréningovú a testovanú množinu dát:


$$E_{\text{train}} = \frac{1}{2} \sum_i^{A_{\text{train}}} (\mathcal{G}(\mathbf{x}_i, \mathbf{w}) - \hat{x}_i)^2 \quad (2)$$

$$E_{\text{test}} = \frac{1}{2} \sum_i^{A_{\text{test}}} (\mathcal{G}(\mathbf{x}_i, \mathbf{w}) - \hat{x}_i)^2 \quad (3)$$

kde E_{train} (E_{test}) je účelová funkcia definovaná pre objekty z tréningovej (testovacej) množiny pre dané hodnoty váhových a prahových koeficientov w . Na základe vety o neurónovej sieti ako univerzálnom aproximátore platí, že pre rastúci počet skrytých neurónov účelová funkcia E_{train} (s adaptovanými váhovými a prahovými koeficientmi) konverguje k nule:

$$\lim_{q \rightarrow \infty} E_{\text{train}} = 0 \quad (4)$$


kde q je počet skrytých neurónov. Interpretácia je veľmi podobná analogickej situácii v regresnej analýze s polynomiálnou modelovou funkciou. Zvyšovaním rádu polynómu dostávame čoraz menšiu hodnotu minimalizovanej účelovej funkcie. Flexibilita polynómu rastie s jeho stupňom (obr. 1).



Obr. 1 Schematické znázornenie simulácie funkcie F , ktorá interpretuje objekty z tréningovej (plné štvorce) aj testovacej množiny (plné krúžky). Funkcia G reprezentuje adaptovanú neurónovú sieť s dostatočným počtom skrytých neurónov, ktorej adaptácia bola vykonaná vzhľadom na objekty tréningovej množiny.

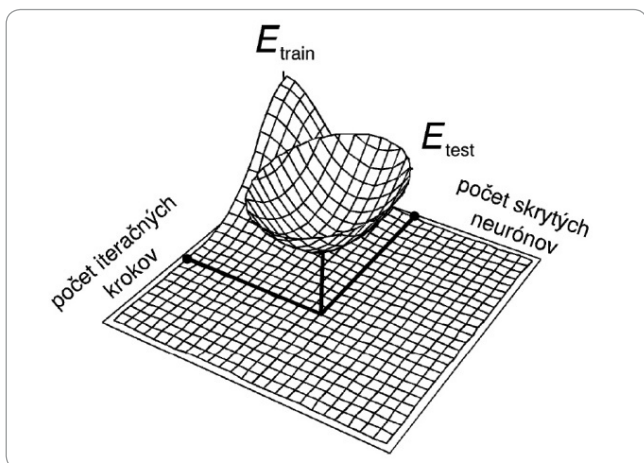
Hodnota účelovej funkcie E_{train} bude klesať s rastom počtu iteračných krokov. Žiaľ, hodnota účelovej funkcie E_{test} bude od určitého počtu iteračných krokov rásť, t. j. zhoršuje sa predikčná schopnosť neurónovej siete s pokračovaním adaptácie neurónovej siete (hovoríme, že neurónová sieť je preučená, obr. 2).

Z uvedených úvah vyplýva, že stanovenie optimálneho počtu skrytých neurónov a počtu iteračných krokov vzhľadom na dané rozdelenie objektov na tréningovú a testovaciu množinu môže byť realizované súčasne. Pre daný počet skrytých neurónov možno nájsť optimálny počet iteračných krokov adaptačného procesu. Tento prístup je založený na poznatku, že zatiaľ čo tréningová účelová funkcia E_{train} klesá s rastúcim počtom skrytých neurónov a/alebo rastúcim počtom iteračných krokov, testovacia účelová funkcia E_{test} vykazuje minimum pre určitý počet skrytých neurónov a iteračných krokov (obr. 2 a 3). Tieto hodnoty, v ktorých má E_{test} minimum, sú optimálne pri použití trojvrstvovej neurónovej siete na klasifikáciu objektov z testovacej množiny A_{test} .



Obr. 2 Priebieha účelových funkcií pre tréningovú a testovaciu množinu v závislosti od počtu iteračných krokov adaptácie (resp. skrytých neurónov) neurónovej siete v dvojrozmernej sústave.

Ako vidno z obr. 3, rozdiely v obidvoch funkciách sú v tom, že účelová funkcia E_{train} je monotónne klesajúca s rastúcim počtom skrytých neurónov a iteračných krokov, pričom účelová funkcia E_{test} má ostré lokálne minimum pre optimálny počet skrytých neurónov a iteračných krokov (hrubé čiary na grafe).



Obr. 3 Schematické znázornenie priebehu účelových funkcií E_{train} a E_{test} vzhľadom na počet skrytých neurónov a iteračných krokov v trojrozmernej sústave.

Tvorba algoritmu pre neurónovú sieť s dopredným šírením

Cieľom tejto časti je naznačiť základné princípy algoritmickej realizácie neurónových sietí s dopredným šírením, ktoré obsahujú skryté neuróny. Pre jednoduchosť budeme uvažovať trojvrstvovú neurónovú sieť, ktorá obsahuje jednu vrstvu skrytých neurónov, pričom neurónov zo susedných vrstiev sú prepojené všetkými možnými spôsobmi (obr. 4). Aktivity skrytých a výstupných neurónov sú určené vzťahmi:


$$z_i = t \left(\sum_{j=1}^n v_{ij} x_j + \theta_i \right) \quad (\text{pre } i = 1, 2, \dots, p) \quad (5)$$

$$y_i = t \left(\sum_{j=1}^p w_{ij} z_j + \vartheta_i \right) \quad (\text{pre } i = 1, 2, \dots, m) \quad (6)$$

kde $t(F(x))$ je sigmoida s parametrami $A = 0$ a $B = 1$.

$$t(\xi) = \frac{1}{1 + e^{-\xi}} \quad (7)$$

Obr. 4 znázorňuje príklad trojvrstvovej neurónovej siete s dopredným šírením, kde vstupná vrstva obsahuje n vstupných neurónov s aktivitami x_1, x_2, \dots, x_n . Skrytá vrstva obsahuje p skrytých neurónov, ich aktivity, resp. prahové koeficienty sú označené z_1, z_2, \dots, z_p , resp. $\theta_1, \theta_2, \dots, \theta_p$. Výstupná vrstva obsahuje m výstupných neurónov, pričom ich aktivity sú označené y_1, y_2, \dots, y_m , resp. $\vartheta_1, \vartheta_2, \dots, \vartheta_m$. Váhové koeficienty medzi vstupnou vrstvou s n vstupnými neurónmi a skrytou vrstvou s p skrytými neurónmi, resp. váhové koeficienty medzi skrytou a výstupnou vrstvou, tvoria maticu $V = (v_{ij})$, resp. maticu $W = (w_{ij})$.



Obr. 4 Trojvrstvová neurónová sieť s dopredným šírením

Výpočet aktivít neurónov pre dané váhové a prahové koeficienty sa nazýva aktívna fáza neurónovej siete. Tieto aktivity pre danú neurónovú sieť sa vypočítajú jednoduchým rekurentným postupom. Predpokladajme, že vstupné aktivity x_1, x_2, \dots, x_n (deskriptory klasifikovaného objektu) sú známe, potom pomocou vzťahu (5) zostrojíme aktivity skrytých neurónov z_1, z_2, \dots, z_p . Následne pomocou vzťahu (6) zostrojíme aktivity výstupných neurónov y_1, y_2, \dots, y_m . Uvedený rekurentný spôsob výpočtu aktivít postupuje zdola nahor neurónovou sieťou. Táto skutočnosť sa odráža v názve týchto sietí ako neurónových sietí s dopredným šírením signálu.

Štatistická analýza vstupných a výstupných dát pri výrobe papiera

Pri výrobe papiera na papierenskom stroji sa pomocou meracích zariadení s časovým rozlíšením do veľkých pamäťových jednotiek ukládajú vstupné a výstupné parametre. Tie sa následne spracúvajú a používajú ako tréningové dáta pre predikčný model za

predpokladu, že charakteristika analyzovaného technologického celku bez akejkoľvek modifikácie sa nemení časom, to znamená, že ak sú v rôznych časoch rovnaké vstupné parametre, totožné sú aj výstupné parametre výrobného procesu. Za predpokladu, že pri výrobe papiera sa vstupné parametre udržiavajú v úzkom intervale hodnôt, je vysoká pravdepodobnosť, že aktuálna konštelácia vstupných parametrov už v histórii nastala alebo nastala situácia k aktuálnej veľmi blízka a k tejto konštelácii existuje aj známa konštelácia výstupných parametrov. Pri realizácii predikčného modelu riadenia sa uplatňujú známe postupy párovania, validácie a selekcie dát.

Párovanie údajov je proces, v rámci ktorého sa spárujú vstupné a výstupné dáta pri zohľadnení retenčných časov jednotlivých procesov.

Validácia dát predstavuje overovanie a vyradovanie dát s extrémne nízkymi a vysokými hodnotami so zvýšenou pravdepodobnosťou chybovosti zapríčinenou napríklad poruchou meracieho zariadenia, výpadkom dávkovacieho zariadenia, poruchou výrobného zariadenia a pod.

Selekcia dát sa robí pomocou regresnej analýzy, pričom sa vyselektujú veličiny, ktoré majú výrazný vplyv na sledovanú výstupnú veličinu. Zároveň sa určia a vyradia tie veličiny, ktoré na výstupné parametre nemajú žiadny alebo iba marginálny vplyv.

Data mining – extrahovanie dát je získavanie netriviálnych, skrytých a potenciálne užitočných a hodnotných informácií z veľkého objemu dát, ktoré sú podkladom na efektívne rozhodnutia v oblasti riadenia a optimalizácie procesu.

Záver

Predikčný model riadenia kvality pri výrobe papiera možno vypracovať v programovacom jazyku Visual Basic.NET Framework 3.5 s použitím úložiska dát v access.mdb databázach. V spojení s dopytovacím jazykom SQL sa vytvoria konektivity na databázy. Uvedeným postupom sa vytvorí predikčný model, ktorý bude

vo forme softvérového produktu pre operačný systém Windows s viacerými funkciami, ako napr. import a triedenie dát podľa kritérií, uloženie projektu ako nový projekt alebo prepísanie ako ďalší projekt, samotnú predikciu a výpočet importovaných dát.

Podakovanie

Článok vznikol vďaka Výskumnému ústavu papiera a celulózy a za podpory projektu VEGA 1/0690/09.

Literatúra

1. Moody, J. – Darken, C.: Neural Computation 1(2):281(1989).
2. Hartman, E. – Keeler, J. D. – Kowalski, J.: Neural Computation 2(2):210(1990).
3. Rudd, J. B. – Tappi, J.: Engineering Conference Proceedings. Atlanta: TAPPI PRESS 1991, p.101.
4. Kooi, S. B. L. – Khorasani, K. – Tappi, J. 75(6):156(1992).
5. Kvasnička, V. – Beňušková, Ľ. – Pospíchal, J. – Farkaš, I. – Tiňo, P. – Kráľ, A.: Úvod do teórie neurónových sietí. Bratislava: Iris 1997, s. 106.

Bc. Peter Medo
Výskumný ústav papiera a celulózy, a.s.
Lamačská cesta 3, 841 04 Bratislava

Ing. František Duchoň, PhD.
Ústav riadenia a priemyselnej informatiky
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita
Ilkovičova 3, 812 19 Bratislava
frantisek.duchon@stuba.sk