

Prognozowanie krótkoterminowe obciążeń systemów elektroenergetycznych z wykorzystaniem rozmytych drzew regresyjnych

Streszczenie. Przedstawiono model prognostyczny oparty na drzewie regresyjnym z rozmytymi węzłami do sporządzania krótkoterminowych prognoz obciążeń systemów elektroenergetycznych. Model operuje na obrazach cykli dobowych szeregów czasowych obciążeń. Odpowiedź modelu wyznaczana jest jako średnia z wartości zapisanych w liściach drzewa ważonych iloczynami stopni przynależności obrazu wejściowego do poszczególnych gałęzi na jego drodze do liści. Parametry nachylenia funkcji przynależności optymalizuje się metodą przeszukiwania turniejowego. Działanie modelu zilustrowano przykładem i porównano z działaniem innych modeli.

Abstract. Short-term load forecasting model based on the regression tree with fuzzy nodes are presented. The model operates on the patterns of the load time series daily cycles. The response of the model is calculated as the mean of the values stored in the tree leaves weighted by the product of the membership degrees of the input pattern to branches on its way to the leaves. The slope parameters of membership functions are optimized using the tournament searching method. The performance of the model is illustrated on the example and compared with other models. (Short-term load forecasting using fuzzy regression trees).

Słowa kluczowe: prognozowanie krótkoterminowe obciążeń systemów elektroenergetycznych, rozmyte drzewa regresyjne, obrazy cykli sezonowych szeregów czasowych.

Keywords: short-term load forecasting, fuzzy regression trees, patterns of the time series seasonal cycles.

doi:10.12915/pe.2014.04.24

Wstęp

Drzewa decyzyjne należą do popularnych narzędzi uczenia maszynowego wykorzystywanych do wnioskowania indukcyjnego. Aproksymują one funkcje docelowe w sposób dyskretny i reprezentują te funkcje w strukturze drzewiastej lub alternatywnie w zbiorze reguł decyzyjnych „jeśli-to”. Charakterystyczny dla drzew decyzyjnych jest podział przestrzeni cech na hiperprostokątności i dopasowanie do każdego z nich prostego modelu (najczęściej jest to stała), który lokalnie aproksymuje funkcję docelową wewnątrz tego hiperprostokątności. Zaletą drzew decyzyjnych w stosunku do innych metod klasyfikacji danych i aproksymacji funkcji, n.p. sieci neuronowych, jest ich bezpośrednia interpretowalność (czytelne reguły logiczne zaimplementowane w drzewie) oraz możliwość działania nie tylko na zmiennych ilościowych lecz także jakościowych (nominalnych i porządkowych). I dotyczy to zarówno zmiennych wyjściowych, jak i wejściowych. Wadą jest aproksymacja funkcji w sposób dyskretny oraz ograniczenie modelowania lokalnego do hiperprostokątności. W następnym rozdziale pokazano jak wady te można zniwelować.

Zależnie od funkcji docelowej drzewo decyzyjne może pełnić rolę klasyfikatora lub modelu regresyjnego. Dalej omawiane będzie drzewo regresyjne w wersji CART (*Classification and Regression Trees*) zaproponowanej przez Breimana [1]. Drzewo CART uczy się aproksymacji funkcji odwzorowującej przykłady $\mathbf{x} \in X = \mathbb{R}^n$ (wektory zmiennych niezależnych) na zbiór liczb rzeczywistych – $f: X \rightarrow \mathbb{R}$. Trening prowadzący do konstrukcji drzewa przebiega na zbiorze uczącym złożonym z przykładów \mathbf{x} oraz wartości funkcji docelowej y dla tych przykładów.

Ilustrację drzewa CART pokazano na rysunku 4. Drzewo składa się z węzłów pośrednich (oznaczonych trójkątami), w których wykonuje się testy na zmiennych niezależnych, węzłów terminalnych (liści, oznaczonych punktami) z etykietami przechowującymi wartości zmiennej zależnej y oraz gałęzi łączących węzły. CART jest drzewem binarnym – z każdego węzła pośredniego wychodzą dwie gałęzie. W procesie konstrukcji drzewa w węzłach pośrednich zachodzi podział zbioru przykładów na dwa podzbiory: przykładów pozytywnych, które spełniają test przypisany do węzła i przykładów negatywnych, które nie

spełniają tego testu. Dąży się do tego, aby wartości funkcji docelowej przykładów w tych podzbiórach miały jak najmniejszą wariancję:

$$(1) \quad s^2(P) = \frac{1}{|P|} \sum_{k \in P} (y_k - \bar{y}_P)^2$$

gdzie: P – zbiór indeksów przykładów przekazanych do węzła potomnego, \bar{y}_P – wartość średnia funkcji docelowej przykładów w zbiorze P .

Wariancja (1) jest miarą "zanieczyszczenia" węzła (*impurity*). Podział zbioru przykładów w węzle na dwa podzbiory w wyniku wykonania testu jest uzasadniony, jeśli prowadzi do zmniejszenia zanieczyszczenia, czyli:

$$(2) \quad p_1 s^2(P_1) + p_0 s^2(P_0) < s^2(P_n)$$

gdzie: P_n , P_1 i P_0 są odpowiednio zbiorami indeksów przykładów w węzle nadrzędnym, w węzle podrzędnym, do którego docierają przykłady pozytywne i w węzle podrzędnym, do którego docierają przykłady negatywne, p_1 i p_0 są frakcjami przykładów pozytywnych i negatywnych w zbiorze P_n : $p_1 = |P_1|/|P_n|$, $p_0 = |P_0|/|P_n|$.

W przypadku zmiennych ciągłych kryterium podziału zbioru P_n w węzle jest test nierównościowy postaci:

$$(3) \quad T(\mathbf{x}) = \begin{cases} 1, & \text{jeśli } x_i > \theta_i \\ 0, & \text{jeśli } x_i \leq \theta_i \end{cases}$$

gdzie θ_i jest wartością progową.

Zmienną do testu oraz wartość progową dobiera się stosując algorytm zachłanny. W każdym węzle rozważa się każdą zmienną i wszystkie możliwości podziału zbioru P_n na dwa podzbiory P_1 i P_0 przy użyciu tej zmiennej. Wymaga to posortowania zbioru P_n względem wartości analizowanej zmiennej x_i i przyjęcia jako wartości progowych środków każdego z przedziałów wyznaczonych przez kolejne wartości tej zmiennej. Liczba testów kandydujących w danym węzle jest nie większa od iloczynu liczby zmiennych i mocy zbioru P_n . Ostatecznie do testu wybiera się tę zmienną i wartość progową, dla których uzyskuje się największą redukcję zanieczyszczenia. Należy zauważyć, że jest to kryterium lokalne, pozwalające znaleźć najlepszy

test w danym węźle w kontekście wcześniejszych wyborów testów do węzłów nadrzędnych i wobec nieznanymi testów w węzłach podrzędnych. Drzewo tak zbudowane niekoniecznie jest optymalne globalnie, tzn. nie osiąga minimum błędu generalizacji.

Drzewo regresyjne najczęściej buduje się według schematu zstępującego. Zaczynając od węzła startowego (korzenia), w którym rozważa się cały zbiór uczący, przemieszczamy się do kolejnych węzłów w wyniku podziału przykładów na podzbiory P_1 i P_0 . Jeśli spełnione jest kryterium utworzenia liścia, np. liczba przykładów docierających do węzła jest mniejsza od L , ustalana jest jego etykieta, najczęściej jako wartość średnia funkcji docelowej przykładów docierających do tego liścia.

Aproksymowaną wartość funkcji dla nowego przykładu odczytuje się z liścia, do którego ten przykład trafił przechodząc od korzenia po ścieżce zależnej od wyników testów przeprowadzanych w węzłach pośrednich.

Wielkość drzewa uzależniona jest od złożoności funkcji docelowej. Wielkością drzewa, która implikuje stopień jego dopasowania do danych uczących (inaczej obciążenie i wariancję modelu), można sterować, np. za pomocą parametru L . Inny sposób polega na utworzeniu rozgałęzienia w węźle tylko wtedy, jeśli zanieczyszczenie ulegnie dostatecznej redukcji; w przeciwnym przypadku tworzy się liść. Można też zbudować drzewo przewymiarowane, a potem przyciąć je do odpowiedniego rozmiaru. Kryteria przycinania (*pruning*) biorą pod uwagę jakość dopasowania i złożoność drzewa mierzona np. liczbą liści [2]. Jeszcze inny sposób ustalania struktury drzewa opiera się na walidacji krzyżowej.

Podstawowy wariant drzewa regresyjnego opisany powyżej oznaczono symbolem RT1.

Drzewa regresyjne z rozmytymi węzłami

Sposób konstrukcji drzewa regresyjnego z rozmytymi węzłami jest taki sam jak drzewa w wariancie podstawowym (ostrym) opisanym powyżej. Inaczej jednak wyznacza się wartość funkcji dla nowego przykładu. Testy przeprowadzane w węzłach pośrednich zmieniają postać:

$$(4) \quad T(\mathbf{x}) = \begin{cases} \mu_1(\mathbf{x}), & \text{jeśli } x_i > \theta_i \\ \mu_0(\mathbf{x}), & \text{jeśli } x_i \leq \theta_i \end{cases}$$

gdzie $\mu_1(\mathbf{x})$ i $\mu_0(\mathbf{x})$ są funkcjami przynależności do podzbiorów przykładów pozytywnych i negatywnych, odpowiednio.

Jeśli przyjąć, że zbiory przykładów pozytywnych reprezentują prawe gałęzie wychodzące z węzłów, a zbiory przykładów negatywnych gałęzie lewe, to $\mu_1(\mathbf{x})$ i $\mu_0(\mathbf{x})$ oznaczają, odpowiednio, przynależność do prawej i lewej gałęzi. W wariancie drzewa oznaczonym RT2 funkcje przynależności opisują wzory:

$$(5a) \quad \mu_1(\mathbf{x}) = \begin{cases} 0, & \text{jeśli } x_i \leq \theta_i - \frac{0,5}{a} \\ 1, & \text{jeśli } x_i \geq \theta_i + \frac{0,5}{a} \\ a(x_i - \theta) + 0,5, & \text{jeśli } \theta_i - \frac{0,5}{a} > x_i > \theta_i + \frac{0,5}{a} \end{cases}$$

$$(5b) \quad \mu_0(\mathbf{x}) = 1 - \mu_1(\mathbf{x})$$

gdzie $a \geq 0$ jest współczynnikiem nachylenia (współczynnikiem kierunkowym prostej $a(x_i - \theta) + 0,5$). Funkcje te pokazano na rysunku 1a.

Aproksymowaną wartość funkcji docelowej szacuje się teraz nie przez odczytanie jej z etykiety liścia, do którego trafił przykład \mathbf{x} , lecz uśredniając wartości z etykiet wszystkich liści z wagami równymi iloczynom stopni

przynależności przykładu do poszczególnych gałęzi na jego drodze do danego liścia. Wyznaczając wartość funkcji uwzględnia się stopnie spełnienia testów, które przekładają się na stopnie przynależności przykładu do lewych i prawych gałęzi wychodzących z węzłów. Drzewo regresyjne z rozmytymi węzłami zobrazowano na rysunku 2. Dla tego przypadku odpowiedź drzewa wynosi:

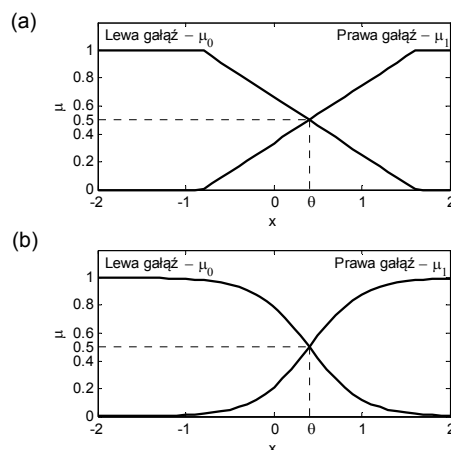
$$(6) \quad y(\mathbf{x}) = y_1^1 \mu_1^1(\mathbf{x}) + y_0^2 \mu_0^2(\mathbf{x}) \mu_0^1(\mathbf{x}) + y_0^3 \mu_0^3(\mathbf{x}) \mu_1^2(\mathbf{x}) \mu_0^1(\mathbf{x}) + y_1^3 \mu_1^3(\mathbf{x}) \mu_1^2(\mathbf{x}) \mu_0^1(\mathbf{x}) = 0,19 \cdot 0,8 + 0,12 \cdot 0,83 \cdot 0,2 + 0,26 \cdot 0 \cdot 0,17 \cdot 0,2 + 0,09 \cdot 1 \cdot 0,17 \cdot 0,2 = 0,175$$

gdzie górne indeksy oznaczają numery węzłów.

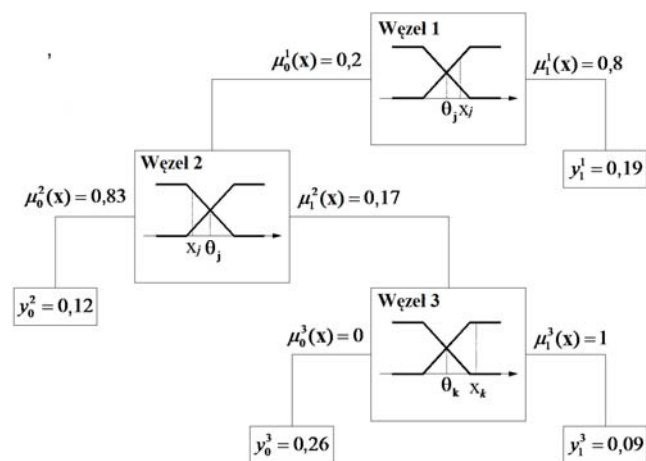
Trzeci wariant drzewa regresyjnego (RT3) jest analogiczny do wariantu drugiego, przy czym stosuje się sigmoidalne funkcje przynależności pokazane na rysunku 1b i wyrażone wzorami:

$$(7) \quad \mu_1(\mathbf{x}) = \frac{1}{1 + \exp(-a(x_i - \theta_i))}, \quad \mu_0(\mathbf{x}) = 1 - \mu_1(\mathbf{x})$$

gdzie $a \geq 0$ jest współczynnikiem nachylenia (tangensem kąta nachylenia stycznej do funkcji w punkcie $(\theta_i, 0,5)$).



Rys.1. Funkcje przynależności (5) – (a) oraz (7) – (b)



Rys.2. Przykładowe drzewo regresyjne z rozmytymi węzłami

Współczynnik nachylenia funkcji przynależności decyduje o stopniu rozmywania. Gdy $a = \infty$, co odpowiada kątowi nachylenia $\alpha = 90^\circ$, otrzymujemy test ostry, gdy $a = 0$ ($\alpha = 0^\circ$) przynależność do obu gałęzi jest jednakowa, równa 0,5. Wartość parametru nachylenia może być jednakowa dla wszystkich węzłów lub dobierana indywidualnie dla każdego węzła. W tym pierwszym przypadku estymacja a

odbywa się metodą przeglądu zupełnego jego dyskretyzowanych wartości w przyjętym zakresie zmienności. W drugim przypadku liczba optymalizowanych zmiennych odpowiadała liczbie węzłów pośrednich m i wymaga bardziej złożonego algorytmu. W części eksperymentalnej do przeszukiwania m -wymiarowej przestrzeni parametrów zastosowano metodę turniejową [3] w wersji do optymalizacji ciągłej. Jest to stochastyczna metoda przeszukiwania odporna na utykanie w minimach lokalnych. Algorytm przetwarza populację l rozwiązań wygenerowanych za pomocą operatora mutacji z rozwiązania bazowego. Mutacja zachodzi według schematu:

$$(8) \quad \alpha' = \alpha + \xi$$

gdzie: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_m]$ – wektor kątów nachylenia funkcji przynależności przypisanych do kolejnych węzłów, ξ – m -wymiarowy wektor liczb losowych z rozkładu $N(0, \sigma)$.

W części eksperymentalnej przyjęto, że parametr σ sterujący rozrzutem mutacji maleje w trakcie procesu przeszukiwania według zależności:

$$(9) \quad \sigma = 2^{\circ} \frac{\ln(G) - \ln(k)}{\ln(G)}$$

gdzie: G jest maksymalną liczbą generacji, a k aktualną wartością licznika generacji.

Jeśli na skutek mutacji kąt przekraczał przedział $[0^\circ, 90^\circ]$, zmieniano jego wartość na najbliższą wartość graniczną.

Najlepsze rozwiązanie spośród wygenerowanych l rozwiązań kandydujących wygrywa turniej i zastępuje rozwiązanie bazowe, z którego generuje się rozwiązania kandydujące w następnej iteracji. Ten mechanizm bezwzględnie zastępowania rozwiązania bazowego przez zwycięzcę turnieju, nawet gdy jego ocena jest niższa, zapewnia możliwość ucieczki z minimów lokalnych.

Przykład aplikacyjny

Modele oparte na drzewach regresyjnych testowano w zadaniach prognozy dobowego przebiegu obciążenia krajowego systemu elektroenergetycznego w styczniu (bez 1 stycznia – przebieg nietypowy) i lipcu 2004 roku z wyprzedzeniem jednodobowym. Dla każdego zadania prognostycznego (prognozy obciążenia w dniu i o godzinie t) konstruowano drzewo regresyjne. Zbiór uczący zawierał przykłady reprezentujące te same typy dni tygodnia, co przykład testowy.

Przykład x jest obrazem dobowej krzywej obciążenia $P_j = [P_{j,1} P_{j,2} \dots P_{j,24}]$ dnia poprzedzającego dzień prognozy, natomiast y jest zakodowaną wartością prognozowanego obciążenia w godzinie t doby $j+\tau$, $P_{j+\tau,t}$. Składowe wektora obrazu $x_j = [x_{j,1} x_{j,2} \dots x_{j,24}]$ i zakodowaną wartość prognozy $y_{j,t}$ wyznacza się ze wzorów:

$$(10) \quad x_{j,k} = \frac{P_{j,k} - \bar{P}_j}{\sqrt{\sum_{l=1}^n (P_{j,l} - \bar{P}_j)^2}}, \quad y_{j,t} = \frac{P_{j+\tau,t} - \bar{P}_j}{\sqrt{\sum_{l=1}^n (P_{j,l} - \bar{P}_j)^2}}$$

gdzie: j – numer dnia, $k = 1, 2, \dots, 24$ – godzina doby, τ – horyzont prognozy, tutaj $\tau = 1$, $P_{j,k}$ – obciążenie o godzinie k w dniu j , \bar{P}_j – moc średnia doby j .


Obraz x zdefiniowany wzorem (10) jest unormowaną wersją wektora P . Celem normalizacji jest filtracja trendu i cykli sezonowych: tygodniowego i rocznego, a także eliminacja niestacjonarności i heteroskedastyczności szeregu czasowego obciążenia. Kodowanie wartości

prognozowanych obciążeń zapewnia ich ujednolicenie i wyraża je za pomocą zmiennych opisujących przebieg obciążenia w najbliższej przeszłości. Pozwala to na dekodowanie, czyli wyznaczenia rzeczywistej wartości obciążenia na podstawie prognozy wartości zakodowanej y .

Przyjęto, że miarą jakości modelu prognostycznego jest błąd MAPE. Optymalne wartości parametrów modelu dobierano w lokalnej wersji procedury minus jednego elementu (*leave-one-out*). Przebiega ona w następujących krokach:

1. W zbiorze uczącym znajdź k najbliższych sąsiadów przykładu testowego x . Zbiór najbliższych sąsiadów będzie zbiorem walidacyjnym.
2. Skonstruuj drzewo regresyjne na zbiorze uczącym pomniejszonym o i -ty element zbioru walidacyjnego.
3. Wyznacz błąd drzewa na i -tym elemencie zbioru walidacyjnego.
4. Powtórz kroki 2 i 3 k -krotnie, biorąc za element i -ty kolejny element ze zbioru walidacyjnego.
5. Uśrednij błędy otrzymane dla wszystkich elementów zbioru walidacyjnego.

W badaniach symulacyjnych przyjęto $k = 12$. Wariant parametru zapewniający najmniejszy błąd na zbiorze walidacyjnym $MAPE_{val}$ przyjmowany jest jako optymalny dla danego zadania prognostycznego.



Rys.3. Optymalne wartości parametru L dla różnych zadań prognostycznych (wariant RT1)

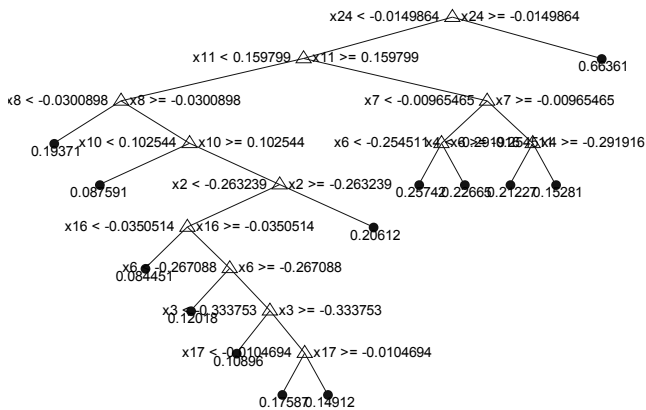
W wersji modelu RT1 dla każdego zadania prognostycznego zmieniano parametr L (liczba przykładów w węzle, poniżej której następuje zamiana tego węzła na liść) od 2 do 60 z krokiem 2. Na rysunku 3 pokazano optymalne wartości parametru L . Jego średnia wartość wynosiła 31. Drzewo regresyjne wygenerowane dla wybranego zadania prognostycznego pokazano rysunku 4.

W wersji RT2 zmieniano kąt nachylenia funkcji przynależności w granicach $\alpha \in (80^\circ, 90^\circ)$ z krokiem $0,5^\circ$. Za L przyjmowano: (a) optymalne wartości znalezione w wariantie RT1 (tę wersję oznaczono symbolem RT2a), (b) stałą wartość, równą 30 (RT2b) i (c) stałą wartość, równą 1 (RT2c). W wariantie RT2c drzewo jest dopasowywane dokładnie do danych uczących i ma maksymalny rozmiar. Estymacja prognozy poprzez agregację wartości wpisanych do etykiet liści z wykorzystaniem rozmytych informacji o „przynależności” przykładu do poszczególnych liści (analogicznie do (6)) zapobiega przeuczeniu modelu.


Ten sam schemat optymalizacji, co dla RT2 zastosowano do RT3 otrzymując warianty RT3a, RT3b i RT3c.

W dalszej części badań dla modelu RT2a dobierano wartości kątów nachylenia funkcji przynależności w każdym węzle indywidualnie za pomocą algorytmu przeszukiwania turniejowego (wariant ten oznaczono symbolem RT4). Rozmiar turnieju wynosił $l = 5m$, a liczba iteracji – 200. Osiągnięto redukcję błędu walidacyjnego z poziomu 1,12 dla RT2a do poziomu 0,74, jednak błąd mierzony na zbiorze testowym wzrósł z poziomu 1,33 do 1,37. Na rysunku 5 pokazano histogram optymalnych wartości kątów nachylenia funkcji przynależności.

Wyniki prognoz dla optymalnych modeli zestawiono w tabeli 1. Dystrybuanty błędów testowych dla modeli RT1, RT2a i RT4 pokazano na rysunku 6.



Rys.4. Drzewo regresyjne utworzone w zadaniu prognozy obciążenia dn. 01.07.2004 r. o godz. 12, (RT1, $L = 18$)




Rys.5. Histogram optymalnych kątów nachylenia funkcji przynależności (RT4)

Tabela 1. Błędy prognoz modeli opartych na drzewach regresyjnych

Wariant drzewa	Parametry	$MAPE_{wal}$	$MAPE_{test}$
RT1	$L = var$	1,27	1,42
RT2a	$L = L_{RT1}, \alpha = var$	1,12	1,33
RT2b	$L = 30, \alpha = var$	1,22	1,36
RT2c	$L = 1, \alpha = var$	1,22	1,33
RT3a	$L = L_{RT1}, \alpha = var$	1,13	1,31
RT3b	$L = 30, \alpha = var$	1,23	1,42
RT3c	$L = 1, \alpha = var$	1,23	1,35
RT4	$L = L_{RT1}, \alpha_1, \dots, \alpha_m = var$	0,74	1,37

W [4] badano inne modele prognostyczne w tych samych zadaniach prognostycznych. Otrzymano następujące błędy $MAPE_{test}$: ARIMA – 1,91, model wygładzania wykładniczego – 1,76, model oparty na sieci neuronowej – 1,14, model oparty na estymatorach jądrowych – 1,05. Te dwa ostatnie modele działające również na obrazach cykli sezonowych generują prognozy obciążenia obarczone mniejszymi błędami niż drzewa regresyjne. Jednak modele konwencjonalne – ARIMA i wygładzanie wykładnicze – dają błędy większe.



Rys.6. Dystrybuanty błędów

Wnioski

Drzewo regresyjne stanowi uniwersalne narzędzie aproksymacji funkcji o wartościach dyskretnych. Dzięki wprowadzeniu rozmytych testów w węzłach można uzyskać ciągłe odpowiedzi. Zastosowanie takiego modelu do prognozowania obciążeń systemów elektroenergetycznych skutkowało redukcją błędu walidacyjnego, szczególnie w przypadku indywidualnej estymacji parametrów funkcji przynależności dla każdego węzła. Niestety nie przełożyło się to na istotną statystycznie poprawę błędu generalizacji mierzonego na zbiorze testowym. Przyczyną tego może być zbyt mała liczba przykładów uczących, które niewystarczająco dokładnie reprezentują otoczenie próbek testowej w 24-wymiarowej przestrzeni.

Drzewa regresyjne charakteryzują się niewielką liczbą parametrów, deterministycznym algorytmem uczenia i czytelną strukturą, która przekłada się na zbiór zrozumiałych dla człowieka reguł decyzyjnych. W kontekście nieliniowych funkcji przynależności model jest nieliniowy. Te czynniki stanowią cenne zalety modelu. Sekwencyjny, zachłanny algorytm konstrukcji drzewa, węzeł po węzle, nie prowadzi jednak do globalnie optymalnego rozwiązania.

Spośród testowanych wariantów rekomenduje się modele RT2c lub RT3c z uwagi na największą elastyczność, która wynika z najbardziej rozbudowanej struktury i możliwości sterowania obciążeniem i wariancją poprzez nachylenia funkcji przynależności. Ponadto w modelach tych nie ma potrzeby estymacji parametru L .

Praca naukowa finansowana ze środków na naukę w latach 2010-2012 jako projekt badawczy nr N N516 415338.

LITERATURA

- [1] Breiman L., Friedman J.H., Olshen R.A., Stone C.J.: Classification and Regression Trees. Wadsworth, Monterey, 1984
- [2] Hastie T., Tibshirani R., Friedman J.: The Elements of Statistical Learning. Data Mining, Inference, and Prediction. Springer, 2009
- [3] Dudek G.: Tournament searching method to feature selection problem. In: Rutkowski L. et al. (eds.): Artificial Intelligence and Soft Computing, LNCS 6114, pp. 437-444
- [4] Dudek G.: Systemy uczące się oparte na podobieństwie obrazów do prognozowania szeregow czasowych obciążeń elektroenergetycznych. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2012

Autor: dr inż. Grzegorz Dudek, Politechnika Częstochowska, Wydział Elektryczny, Instytut Elektroenergetyki, al. Armii Krajowej 17, 42-200 Częstochowa, E-mail: dudek@el.pcz.czyst.pl