

NÁVRH A REALIZACE KLASIFIKÁTORU CHYB DIAGNOSTICKÉHO SYSTÉMU S VYUŽITÍM NEURONOVÝCH SÍTÍ

Michal MUSIL

Katedra provozní spolehlivosti, diagnostiky a mechaniky v dopravě

1. Úvod

Diagnostiku poruchy systému lze obecně rozdělit na tři základní fáze - detekce, lokalizace a klasifikace. Detekce znamená získání informace o tom, že se v daném diagnostickém objektu vyskytuje porucha, lokalizace znamená určení místa výskytu poruchy a klasifikace je konkretizování typu poruchy diagnostického objektu.

Klasifikátor chyb představuje systém, který dokáže lokalizované poruchy konkretizovat, tedy zařadit tyto poruchy do jednotlivých předem daných kategorií. V případě výskytu předem neuvažované poruchy je klasifikátorem tato porucha označena jako nezařaditelná a je zde možnost tuto poruchu zařadit do databáze klasifikovaných poruch.

Důležitým požadavkem na klasifikátor je možnost klasifikace vícenásobných poruch tj. v diagnostickém signálu se vyskytuje několik příznaků poruch současně.

Jako hlavní prostředek pro realizaci klasifikátoru chyb budou použity neuronové sítě. Tyto sítě budou implementovány pro použití na PC prostřednictvím softwarového simulátoru neuronových sítí systémem Matlab/Simulink.

V teoretickém úvodu budou popsány některé konkrétní typy neuronových sítí a jejich použitelnost v dané problematice. Dále deterministické metody klasifikace poruch


a jejich vlastnosti. Nedílnou součástí řešení je také ověření účinnosti klasifikátoru chyb na konkrétních reálných signálech, ve kterých bude simulováno 16 různých chyb. Použité signály budou reálné signály z tenzometrických měření (např. měření silových účinků železničních vozidel na kolejnicové pásy) a reálné zvukové signály. Tímto ověřeníme účinnost navrhovaného klasifikátoru v reálných technických prostředích z důvodu možného využívání diagnostického systému například při praktických měřeních. Součástí příspěvku je i vyhodnocení účinnosti navrhovaného klasifikátoru a možnosti jeho rozšíření o další soubor chyb.

V tomto úvodu je nutno podotknout, že popisovaný klasifikátor je možno uplatnit jednak při klasifikaci chyb v signálech získaných například při měřeních na dopravních prostředcích a dopravní cestě a jednak v obecném diagnostickém systému pro analýzu diagnostických signálů a klasifikaci poruch reálného diagnostického objektu.

2. Vybrané typy neuronových sítí a jejich vlastnosti

Hopfieldova síť

Tato síť se skládá z tolika neuronů, kolik má vstupů. Hopfieldova síť patří svoji strukturou mezi asociativní paměti, tj. její odpovědí na předložený vzor je přímo nalezený vzor. Pokud bychom chtěli udělat z Hopfieldovy sítě klasický klasifikátor, museli bychom rozšířit naši síť o komparátor, který by vzal odpověď sítě a porovnal ji se všemi dosud naučenými vzory. Algoritmus učení se této síti je následující: Pro každý vzor vytvoříme díleč matici dimenze $N \times N$, kde N je počet vstupů. Tato matice bude tvořena prvky, které vzniknou vynásobením i -tého vstupu j tým vstupem, přičemž jedná-li se o stejný vstup ($i = j$), je váhový koeficient nulový. Tím vznikne symetrická matice obsahující $+1$ a -1 s výjimkou nulové diagonály. Výsledná čtvercová matice vah, vznikne součtem všech dílečích matic jednotlivých vzorů, kterých je M .



Obr. 1 Hopfieldova síť

Fig. 1 Hopfield's network

Fáze učení se sítí

Nastavení vah podle vstupních vzorů:

$$w_{ij} = \sum_{s=0}^{M-1} x_i^s x_j^s \quad \text{pro } i \neq j, \quad (1)$$

$$w_{ij} = 0 \quad \text{pro } i = j. \quad (2)$$

V této rovnici je w_{ij} váha mezi neuronem i a j a x_i resp x_j je i -tý (j -tý) element s -tého vstupního vzoru, který nabývá hodnoty $+1$ nebo -1 .

Další vlastnosti této sítí (možnost práce sítí i s reálnými vstupy) a jejich modifikací jsou uvedeny v [2].

Fáze vybavování

V této fázi předložíme sítí nový neznámý obrazec na vstupy sítí a postupně počítáme výstupy sítí podle níže uvedeného vztahu. Po každém průběhu jsou výstupy poopraveny a slouží opět jako vstupy do sítí :

$$y_i(0) = x_i, i = 0, \dots, N-1, \quad (3)$$


$$y_i(t+1) = F\left(\sum_{j=0}^{N-1} w_{ij}(t) \cdot y_j(t)\right), j = 0, \dots, N-1. \quad (4)$$

Tento postup opakujeme tak dlouho, dokud se výstupy během dvou cyklů nezmění ani na jednom neuronu. Takto získané výstupy přímo odpovídají vybavenému vzoru.

Princip Hopfieldovy sítí je založen na porovnávání obrazců pomocí Hammingovy metriky a za správnou odpověď se bere ten obrazec, který má tuto vzdálenost nejmenší.

Vícevrstvé sítí

V úvodu vícevrstevných neuronových sítí začneme klasickou sítí – perceptronem. Perceptronová síť je třívrstvá. Vstupní vrstva funguje jako vrstva rozvíčkovácí (rozdiřlovací), jejím úkolem je mapování dvourozměrného pole čidel a transformace na jednorozměrný vektor procesorových elementů. Druhou vrstvu tvoří detektory rysů (příznaků). Každý z nich je náhodně spojen s prvky vrstvy vstupní. Poslední, třetí vrstva obsahuje rozpoznávací vzorů. Zatímco váhy ve vstupní a druhé vrstvě jsou pevné, lze váhy na vstupech vrstvy výstupní při trénování nastavovat. Variací perceptronu je MP perceptron, jedná se o jednovrstvou síť, jejíž předností je, že se velmi snadno geometricky interpretovat učící proces. Další variací perceptronu jsou sítí Adaline/Madaline [2]. Použitím McCulloch-Pittsova modelu neuronu ve vícevrstvé struktuře vzniká vícevrstvý perceptron. Tato síť vyžaduje i změnu učícího algoritmu, vzniká algoritmus zpětného šíření – Back propagation.



Obr. 2 Vícevrstvá neuronová síť
Fig. 2 Multilayer neural network

Na **obr. 2** je zobrazena vícevrstvá neuronová síť, obsahující - vstupní, skryté a výstupní vrstvy. Vstupní a výstupní vrstvy jsou určeny počtem a typem vstupních a výstupních proměnných modelovaného systému. Počet skrytých vrstev a počet neuronů skryté vrstvy není zcela libovolný a je dán typem sítě a aplikací sítě. Např. velký počet neuronů urychluje dobu učení se sítí, ovšem znesnadňuje testování sítě.

Proces učení sítě představuje ve většině případů ladění vah vstupů neuronů. Jen v ojedinělých případech se uvažuje o změně topologie sítě. Procedury nastavování vah v sobě obsahují jednak určitou strategii a jednak numerické postupy vyjádřené matematickými vztahy. Základ pro algoritmy učení se sítí poskytují dvě pravidla a to jsou Hebbovo pravidlo a Delta pravidlo.

Hebbovo pravidlo:

$$\Delta w_{ij}(k+1) = h \cdot a_i(k) \cdot y_j(k) . \quad (5)$$

Delta pravidlo:

$$\Delta w_{ij}(k+1) = h \cdot (s_i(k) - a_i(k)) \cdot y_j(k) . \quad (6)$$

$\Delta w_{ij}(k+1)$ je změna váhy $w_{ij}(k)$. Předpokládá se korekce $w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k+1)$, kde $a_i(k)$ představuje aktivaci funkce i -tém neuronu, $s_i(k)$ představuje vzor na který je i -tý neuron trénován, h je konstanta určující rychlost učení se sítí.

Kohonenova síť

Jedná se o tzv. samoorganizující neuronové síť, které ke svému učení nepotřebují učitele. Základním principem jejich funkce je shluková analýza, tj. schopnost algoritmu nalézt určité vlastnosti a závislosti přímo v předkládaných trénovacích datech bez přítomnosti nějaké vnější informace, jako je tomu např. u perceptronových sítí. Struktura neuronu v Kohonenově síti je odlišná od neuronu v perceptronové síti. Počet vstupů, které přicházejí do neuronu, je roven počtu vstupů do Kohonenovy sítě. Váhy

ti chto vstupů slouží k zakódování vzorů, které reprezentují předložené vzory, stejní jako u perceptronu. Vlastní přenosovou funkci tyto neurony v podstatě nemají. Jedinou operací, kterou neuron provádí, je výpočet vzdálenosti (odchylky) předloženého vzoru od vzoru zakódovaného ve vahách daného neuronu podle vztahu:

$$d = \sum_{i=0}^{N-1} [x_i(t) - w_i(t)]^2 \quad (7)$$

kde $x_i(t)$ jsou jednotlivé elementy vstupního vzoru a $w_i(t)$ jsou odpovídající váhy neuronu, které představují zakódované vzory.

Vstupní neurony jsou mezi sebou vzájemně propojeny, ale jen se sousedními neurony. Každý vstup je spojen s každým neuronem mřížky. Každý neuron v mřížce je přímo výstupem.

Podrobně ji v [2]. Typickou aplikací těchto neuronových sítí je rozpoznávání řeči.

ART síť

Mnoho paradigmat neuronových sítí naráží na problém zvaný „problém promínné stability“. Jedná se vlastně o to, že síť není schopna naučit se novou informaci bez poškození dříve uložené informace. Tento jev je způsoben změnami vah sítí.

Adaptivní rezonanční teorie (ART) byla vyvinuta pro modelování mohutné paralelní architektury pro samoučící se síť k rozpoznávání obrazů. Hlavní vlastností ART sítí je její schopnost přepínat mezi tvárným a stabilním módem. Tvárným módem rozumíme učící stav, kdy poáteření parametry mohou být modifikovány. Stabilní mód je naopak stav, kdy je síť již pevně nastavena a chová se jako hotový klasifikátor. K dalším výhodám ART sítí patří citlivost na kontext a schopnost příměně eliminovat špatné informace.

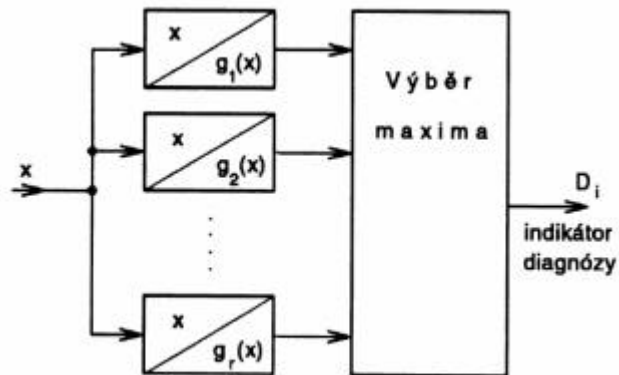
Učení ART sítí je odlišné od jiných neuronových sítí. Síť je navržena tak, že v každém okamžiku je možno předat nový vzor. Tato síť je schopna učít se i v promínném prostředí.

Z dalších používaných neuronových sítí se jedná zejména o síť s přenosovou funkcí s radiální bází (RBF- Radial Basis Function), nebo rekurentní Elmanovy síť.

3. Deterministické metody klasifikace poruch

Metoda diskriminačních funkcí

Tato metoda využívá hypotézu shlukování bodů interpretujících zobrazení jedné a téže diagnózy jednoho objektu nebo více stejných objektů do jediného shluku bodů v n -rozměrném páznakovém prostoru. Podobnost obrazů technického stavu se společnou diagnózou nastává při vhodném výběru páznaků, čemuž odpovídá geometrická blízkost koncových bodů vektorů páznaků. Shluky odpovídající jednotlivým diagnózám se snažíme oddělit rozlišovací nadplochou. Existuje-li pro určitou úlohu klasifikace taková rozlišující nadplocha, že všechny obrazy jedné, resp. druhé diagnózy leží na opačných stranách této nadplochy, říkáme, že jde o úlohu se separabilními množinami obrazů. Pro klasifikaci do dvou tříd vystačíme s jednou rozlišovací nadplochou. Ve dvourozměrném páznakovém prostoru se nadplocha redukuje na čáru. Je-li rozlišující nadplocha nadrovinou hovoříme o rozpoznávání s lineární separabilitou. Označíme n -rozměrný páznakový prostor X^n . Nechť rozhodovací pravidlo rozdělí prostor X^n na R vzájemně disjunktních podmnožin (podprostorů) $X = (X_1, X_2, \dots, X_R)$ zobrazujících jednotlivé diagnózy D_1, D_2, \dots, D_R .



Obr. 3 Blokové schéma lineárního klasifikátoru

Fig. 3 Block diagram of a linear classifier

Rozhodovací pravidlo rozděluje páznakový prostor tak, že každému sloupcovému vektoru páznaků x přiřadí indikátor diagnózy.

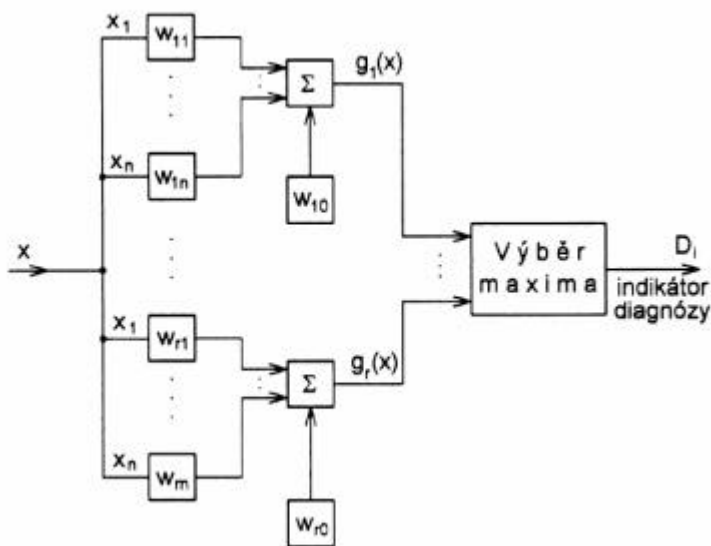
Rozlišující nadplochy podprostorů lze určit diskriminačními funkcemi $g_i(x)$, kde $i = 1, 2, \dots, R$. Diskriminační funkce $g_i(x)$ pro i -tou diagnózu je definována tak, aby pro všechna $x \in X_i$ platilo:

$$g_i(x) \geq g_j(x) \quad \text{pro } j = 1, 2, \dots, R. \quad (8)$$

Rozdílující nadplocha mezi sousedními podprostory X_i a X_j je určena rovnicí:

$$g_i(\mathbf{x}) - g_j(\mathbf{x}) = 0. \quad (9)$$

Pro konkrétní vektor \mathbf{x} je diskriminační funkce skalární a jednohodnotovou funkcí. Blokové schéma klasifikátoru založeného na metodě diskriminačních funkcí je na **obr. 4**.



Obr. 4 Blokové schéma klasifikátoru pro metodu diskriminačních funkcí

Fig. 4 Block diagram of a classifier for the method of discriminated functions

Všechny pážnaky jsou současně pávedeny do R bloků. V každém bloku se vyhodnotí diskriminační funkce $g_i(\mathbf{x})$. Na výstupu bloku "vyhodnocení maxima" se objeví indikátor diagnózy D_i , jejíž diskriminační funkce má pro daný vektor \mathbf{x} maximální hodnotu.

Nejjednodušším a nejrozšířením typem diskriminační funkce je lineární diskriminační funkce daná vztahem:

$$g_i(\mathbf{x}) = \sum_{j=1}^n w_{ij} \cdot x_j + w_{i0} = \mathbf{w}_i^T \cdot \mathbf{x} + w_{i0}. \quad (10)$$

Kde w_{ij} je váha j -tého pážnaku funkce $g_i(\mathbf{x})$, $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ je váhový vektor a w_{i0} je práh funkce $g_i(\mathbf{x})$.

Jestliže diagnózy odpovídající indikátorům D_k a D_L mají v pážnakovém prostoru společnou hranici, pak rozdílnými nadplochami jsou rozdílnými nadrovinami dané rovnicemi:

$$\sum_{j=1}^n (w_{Kj} - w_{Lj}) \cdot x_j + (w_{K0} - w_{L0}) = (w_{K0} - w_{L0})^T \cdot \mathbf{x} + (w_{K0} - w_{L0}) = 0. \quad (11)$$

Musí být splněny následující podmínky:

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \cdot \mathbf{x} > 0 \quad \text{pro } \mathbf{x} \in D_i, \quad (12)$$

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \cdot \mathbf{x} < 0 \quad \text{pro } \mathbf{x} \in D_j. \quad (13)$$

Rozdílní nadplochy jsou pak dány rovnicemi:

$$g_i(\mathbf{x}) = 0. \quad (14)$$

Výhodou takto řešené klasifikace je zjednodušení bloku "výběr maxima" pomocí bloků:

$$D_i = \text{sign } g_i(\mathbf{x}). \quad (15)$$

Nevýhodou tohoto řešení je nemožnost rozpoznání za předpokladu, že nerovnost $g_i(\mathbf{x}) > 0$ platí pro více než jednu diagnózu. Bezchybovou je tato metoda při tzv. dichotomii, tj. případě rozpoznávání jen dvou diagnóz tj. $R = 2$.

Metoda minimální vzdálenosti od etalonu

Tato metoda rovněž předpokládá shlukový charakter obrazů jednotlivých diagnóz. Nejprve uvažujme diagnózy charakterizované jediným pážnakovým vektorem – **etalonem**. Předpokládejme, že pro R diagnóz technických stavů je R etalonů

$$\mathbf{x}_E = \{\mathbf{x}_{E1}, \mathbf{x}_{E2}, \dots, \mathbf{x}_{ER}\}, \quad (16)$$

příslušejících daným diagnózám. Podstata této metody je založena na konstatování, že vzdálenost vektoru pážnaků \mathbf{x} příslušejícího i -té diagnóze má od etalonu této diagnózy tj. od \mathbf{x}_{Ei} menší vzdálenost $\mathbf{d} = \mathbf{d}(\mathbf{x}, \mathbf{x}_{Ei})$ než jsou vzdálenosti $\mathbf{d} = \mathbf{d}(\mathbf{x}, \mathbf{x}_{Ej})$ od ostatních etalonů \mathbf{x}_{Ej} diagnóz D_j , kde $j = 1, 2, \dots, R$ a $j \neq i$. Platí tedy: $\mathbf{x} \in D_i$; $\mathbf{d} < \mathbf{d}_j$.

Jinak řečeno zmišný vektor pážnaků \mathbf{x} zařadíme do diagnózy D_i tehdy, má-li etalon \mathbf{x}_{Ei} od vektoru \mathbf{x} nejmenší vzdálenost neboli $\mathbf{d} = \min_j \mathbf{d}_j$ pro $j = 1, 2, \dots, R$.

V matematické analýze platí v n -rozměrném euklidovském prostoru pro normu vektoru pážnaků:

$$\|\mathbf{x}\| = \sqrt{\mathbf{x}^T \mathbf{x}} = \sqrt{\sum_{p=1}^n x_p^2}. \quad (17)$$

Pro vzdálenost dvou bodů tj. zmišného vektoru pážnaků \mathbf{x} a etalonu \mathbf{x}_{Ei} platí:

$$\mathbf{d}(\mathbf{x}, \mathbf{x}_{Ei}) = \|\mathbf{x} - \mathbf{x}_{Ei}\| = \sqrt{(\mathbf{x} - \mathbf{x}_{Ei})^T (\mathbf{x} - \mathbf{x}_{Ei})}. \quad (18)$$

Rozpoznání i -té diagnózy lze vyjádřit následovně:

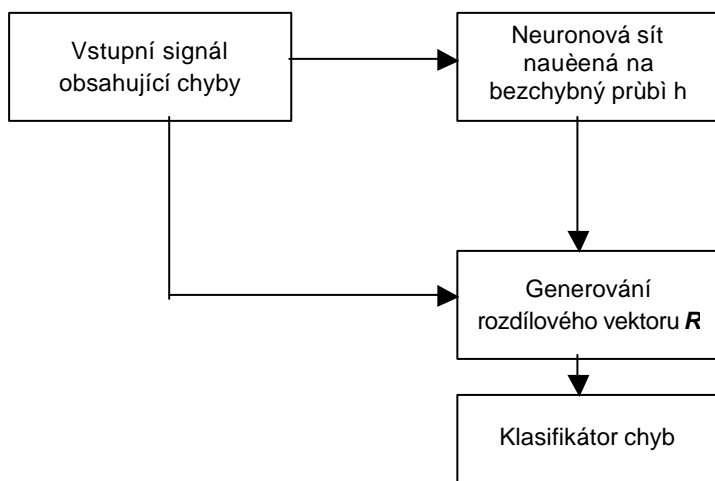
$$\|\mathbf{x} - \mathbf{x}_{Ei}\| = \min_j \|\mathbf{x} - \mathbf{x}_{Ej}\| \Rightarrow (\mathbf{x} \in D_i) \quad \text{pro } j = 1, 2, \dots, R. \quad (19)$$

Rozšířením metody minimální vzdálenosti od etalonu je metoda minimální vzdálenosti od etalonu s diskriminačními funkcemi po úsecích lineárními. Touto metodou lze řešit případy odpovídající lineární neseparabilním množinám prvků. Metoda je založena na předpokladu, že diagnóza D_i nebude reprezentována jediným etalonem, ale množinou etalonů. Podrobněji o této metodě v [6].

4. Návrh neuronového klasifikátoru

Klasifikátor chyb představuje nedílnou součást každého diagnostického systému. Diagnostiku chyby v systému (signálu) lze rozdělit na tři fáze. První fází je detekce chyby, druhou fází lokalizace a třetí fází klasifikace chyby. Detekce a lokalizace poruchy (chyby) signálu je provedena na základě testování signálu neuronovou sítí, která je naučená na správný (bezchybný) průběh signálu. Pokud na vstup takovéto neuronové sítě přivedeme signál obsahující chyby, projeví se to v rozdílu vstupního signálu a signálu predikovaného neuronovou sítí. Rozdílem těchto dvou signálů získáme tzv. **rozdílový vektor R** ve kterém jsou jednoznačně určena místa výskytu poruchy, tento vektor R tedy poskytuje informaci o místě výskytu poruchy dále o počtu poruch v daném signálu (posloupnosti vzorků signálu), o tom zda se porucha vyskytuje v pravidelných intervalech atd., tedy veškeré informace týkající se výskytu poruch. Na **obr. 5** je zobrazen diagnostický systém pro generování rozdílového vektoru R a navazující klasifikátor chyb.


Generování vektoru R je uvedeno na příkladech. Na **obr. 6** je lokalizace jednoduché poruchy výpadky vzorků sinusového signálu. Nejprve je zobrazen vstupní signál obsahující chybu, dále signál predikovaný neuronovou sítí a rozdílový vektor R . Na **obr. 7** je zobrazena lokalizace periodicky se vyskytující poruchy výpadky vzorků ve složitějším signálu. Je jasné, že signál může obsahovat i více různých chyb současně.



Obr. 5 Diagnostický systém s klasifikátorem chyb
Fig. 5 Diagnostic system with an error classifier


Vektor R tedy poskytuje základní informaci o výskytu chyb v signálu. Ovšem pro kompletní identifikaci poruchy je nutné provést její klasifikaci.

Pro možnost klasifikace poruchy se nabízí několik řešení. Klasifikaci chyb podle rozdílového vektoru R je možno realizovat pomocí několika neuronových sítí, přičemž je každá síť naučena na konkrétní rozdílový vektor R . Pokud uvažujeme v systému např. klasifikaci deseti typů chyb, je nutné aby vektor R byl převeden na vstupy deseti paralelně pracujících neuronových sítí přičemž každá z těchto sítí bude naučena na jednu z uvažovaných chyb, respektive na rozdílový vektor R odpovídající dané chybě. Vlastní klasifikace je provedena na základě porovnání výstupů jednotlivých sítí a to tím způsobem že se jedná o tu chybu pro kterou má síť nejmenší rozdíl mezi vstupním signálem R a jeho predikcí neuronovou sítí. Toto je vyjádřeno na **obr. 8**. Výstupní chyba sítí, tedy celkový součet dílčích chyb (rozdílů vstupního a predikovaného signálu) může mít tvar skalární nebo vektorový. V jednodušších případech, kdy pro jednotlivé typy chyb existuje jednoznačné přeznění poruchy k dané hodnotě výstupní chyby sítí stačí použít skalární tvar. Pokud se jedná o chyby složitější a není možné provést jednoznačnou klasifikaci poruchy na základě skalárního tvaru, je nutné výstupní součet rozdílů signálů vyjádřit ve vektorové podobě, např. rozdělením na několik intervalů a pro každý interval je proveden součet rozdílů signálů zvlášť, tím dostáváme vektorový tvar, který umožní klasifikaci i složitějších poruch.

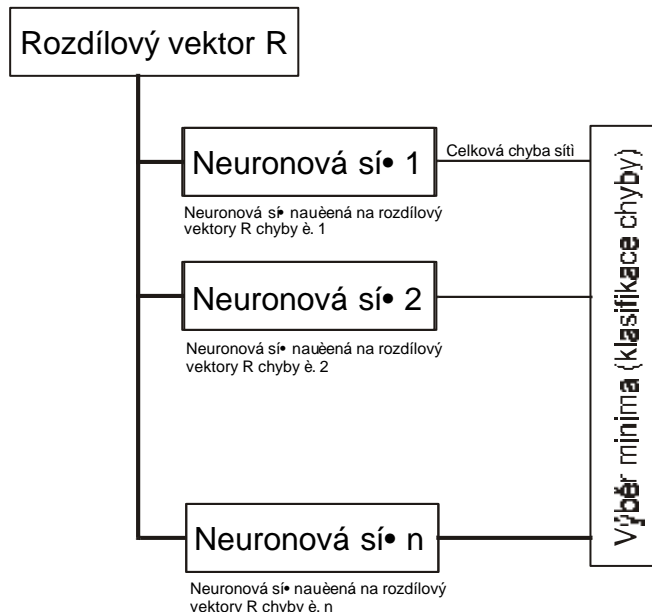


Obr. 6 Lokalizace jednoduché chyby v sinusovém signálu

Fig. 6 Localisation of a simple error in the sinusoidal signal



Obr. 7 Lokalizace periodicky se opakující chyby
Fig. 7 Localisation of a periodically repeating error



Obr. 8 Klasifikace poruchy na základě analýzy rozdílového vektoru R
Fig. 8 Classification of an error on the base of an analysis of the differential vector R

Praktické zkušenosti při klasifikaci chyb na základě analýzy rozdílového vektoru R ukazují, že tento vektor má v nich kterých případech pro různé typy chyb velmi podobný tvar a také značně složitou strukturu pro možnost naučit sílu přesně na konkrétní rozdílový vektor. Zde dochází k nejednoznačné klasifikaci chyb, k překrývání chyb atd. Z tohoto důvodu je klasifikace chyb řešena v této práci níže popsaným způsobem.

Další možnost klasifikace chyb je taková, že na základě lokalizace chyb vektorem R jsou separovány části signálu obsahující chyby (konkrétní délka separované části signálu samozřejmě závisí na konkrétních podmínkách a nastavení systému). Pro účely této práce byly při výskytu chyby vybrány úseky o délce 100 vzorků signálu. Jedná se v podstatě o stejné uspořádání paralelních neuronových sítí jako při analýze vektoru R , ovšem zde jsou jednotlivé neuronové sítě naučené na jednotlivé uvažované chyby. Tedy při výskytu některé chyby je separovaná část signálu s chybou přivedena na vstupy všech neuronových sítí a na základě porovnání výstupních celkových chyb jednotlivých sítí je chyba konkretizována.

Z praktického hlediska je nutno uvažovat i možnost výskytu tzv. neznámé chyby, tedy takové chyby, s kterou jsme předem při návrhu jednotlivých neuronových sítí nepočítali. Při tomto uspořádání systému je i neznámá chyba detekována, protože vstupní neuronové sítě pro lokalizaci poruch jsou naučeny na správný průběh signálu. Pokud systém lokalizuje chybu, která není dosud uvažována, je možné na tuto chybu naučit další neuronovou sílu a tím rozšířit možnosti diagnostického systému.

5. Soubor chyb určených k testování klasifikátoru

Pro testování klasifikátoru bylo stanoveno 16 chyb v několika kategoriích, které byly aplikovány na různé typy signálů – konkrétně na základní **referenční sinusový signál** dále na **signál získaný při reálných tenzometrických měřeních** a na **reálný zvukový signál**.

Při stanovení typů a kategorií chyb byla uvažována reálná možnost výskytu těchto chyb v praxi, proto byly stanoveny následující kategorie chyb. Kategorie vycházejí z požadavku simulovat v signálech chyby, jejichž výskyt je v praxi nejméně frekventovanější.

Chyby typu DROP-OUT – výpadky několika vzorků signálu -kategorie A:

1. výpadek 5 vzorků,
2. výpadek 20 vzorků,
3. výpadek 50 vzorků,
4. výpadek 100 vzorků,
5. periodický výpadek 5 vzorků (100 vzorků signál, 5 vzorků výpadek, 100 vzorků signál),
6. periodický výpadek 1 vzorku (100 vzorků signál, 1 vzorek výpadek).

Chyby typu amplitudové zkreslení - kategorie B:

7. 10 vzorků signálu - max. amplituda,
8. 20 vzorků signálu - max. amplituda,
9. 50 vzorků signálu - max. amplituda,
10. periodicky chyba è. 7 (100, 10, 100,...),
11. periodicky jako chyba è.10, amplituda snížena vždy na 50%.

Chyby typu náhodný signál - kategorie C:

12. náhodný signál – 5 vzorků,
13. náhodný signál – 10 vzorků,
14. periodické opakování chyby è.12 (100, 5, 100).

Chyba typu náhodný impulsní šum v signálu - kategorie D:



15. náhodně 5 impulsů v signálu.

Chyba typu limitace signálu - kategorie E:


16. limitace signálu (ořezání špiček signálu).

6. Praktické ověřování èinnosti neuronového klasifikátoru

Dále budou uvedeny praktické příklady analýzy separovaných èástí signálu s chybou. Na **obr. 9** je signál obsahující chybu è.1 – výpadek 5 vzorků signálu (vlevo), separovaná èást jak již bylo výše uvedeno má délku 100 vzorků. Na obrázku je uveden signál predikovaný neuronovou sítí nauèenou na tuto chybu (vpravo) a okamžitá a celková výstupní chyba sítì (**obr. 10**).





Obr. 9 Separovaná èást signálu obsahující chybu è.1 (vlevo) a predikovaný signál
Fig. 9 Separated part of the signal containing an error Nr 1 (left) and predicted signal



Obr. 10 Okamžitá a celková chyba sítě


Fig. 10 Instantaneous and total error of the network

Dále je uveden příklad klasifikace chyby è. 7 – maximální amplituda 5 vzorků signálu. Na **obr. 11** je výsledek testování tohoto signálu s chybou neuronovou sítí naučenou na tuto chybu a na **obr. 12** je výsledek testování tohoto signálu neuronovou sítí naučenou na chybu è. 1




Obr. 11a Testování signálu s chybou è.7 sítí naučenou na chybu è.7

Fig. 11a Testing of the signal with the error Nr 7 by means of the network learnt to the error Nr 7



Obr. 11b Okamžitá a celková chyba sítě

Fig. 11b Instantaneous and total error of the network




Obr. 12 Testování signálu s chybou è.7 sítí nauèené na chybu è.1


Fig. 12 Testing of the signal with the error Nr 7 learnt to the error Nr 1 and an instantaneous as well as a total error of the network

Na základì uvedených pøíkladù je jednoznaènì zøejmá èinnost klasifikátoru. Napøíklad pro poruchu è.7 je výstupní chyba paralelnì pracující neuronové sítí nauèené na tuto chybu 5 mV ovšem výstupní chyba sítí nauèené na poruchu è.1 je pø vstupní poruše è.7 27 mV, klasifikátor tedy vybere tu poruchu, pro kterou má jedna z paralelnì pracujících neuronových sítí nejmenší výstupní celkovou chybu.

Dále uvádím pøíklad detekce, lokalizace a klasifikace poruchy v reálném zvukovém signálu.



Obr. 13 Detekce poruch typu maximální amplituda 10 vzorkù v hudebním signálu
Fig. 13 Detection of errors with the type of maximum amplitude for 10 samples in a real music signal



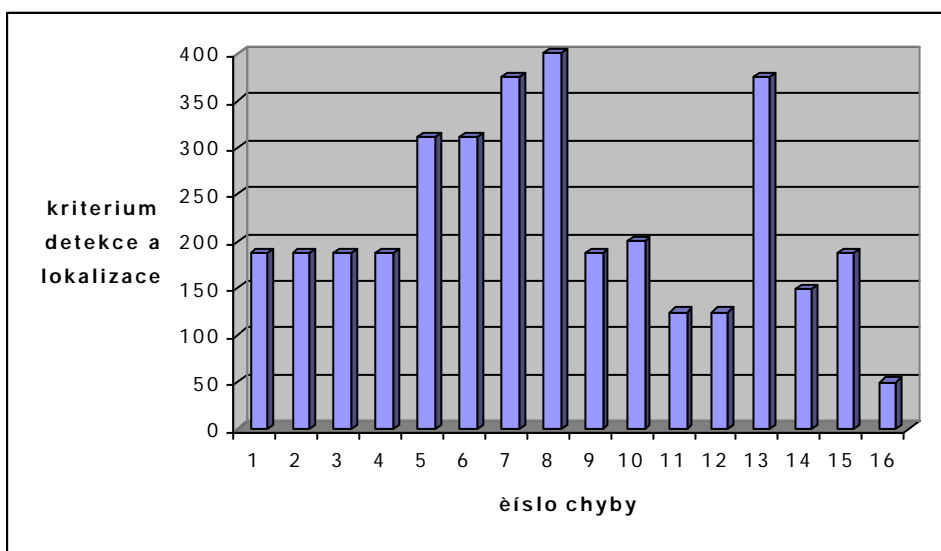
Obr. 14 Klasifikace chyby č. 7 v reálném zvukovém signálu

Fig. 14 Classification of the error Nr 7 in a real music signal

7. Hodnocení účinnosti neuronového klasifikátoru

Hodnocení úspěšnosti popisovaných metod je rozděleno na část detekce a lokalizace poruchy signálu a na část klasifikace.


Kritériem hodnocení úspěšnosti detekce a lokalizace K_{DL} definují jako poměr amplitudy signálu rozdílového vektoru v místě výskytu poruchy k amplitudě v místě bezporuchovém. Výsledky tohoto hodnocení jsou zřejmé z uvedené tabulky a grafu. Z uvedeného hodnocení vyplývá, že všechny uvažované chyby byly diagnostickým systémem jednoznačně detekovány a lokalizovány nebo místa výskytu chyb jsou v rozdílovém vektoru charakterizována výraznými lokálními extrémy.



Obr. 15 Hodnocení úspěšnosti detekce a lokalizace poruchy v signálu

Fig. 15 Evaluation of the successfulness of detection and localisation of an error in the signal

Kritériem hodnocení úspěšnosti klasifikace K_{KL} definují jako poměr celkové výstupní chyby sítě s druhou nejvyšší výstupní chybou k výstupní chybě sítě odpovídající právě úspěšně klasifikovanému typu poruchy signálu, což znamená, že ze 16-ti paralelně pracujících neuronových sítí, je pouze jedna ze sítí naučena na právě klasifikovanou poruchu signálu, tato síť bude mít nejmenší výstupní chybu, ostatní sítě budou mít výstupní chybu větší což všechny provedené experimenty potvrdily. Pokud má nejmenší výstupní chybu síť neodpovídající právě klasifikované chybě je klasifikace považována za neúspěšnou, což v tomto případě byly chyby typu náhodný signál.



Obr. 16 Hodnocení úspěšnosti klasifikace poruchy v signálu

Fig. 16 Evaluation of the successfulness of classification of an error in the signal

8. Závěr

Na základě teoretického rozboru dějin vzniku chyb, možností jejich diagnostiky a aplikací různých diagnostických metod na stanovené typy signálů byla zvolena diagnostická metoda využívající umělých neuronových sítí pro detekci, lokalizaci a klasifikaci chyb v signálech. Je jasné, že pro jednoduché typy signálů jsou jednotlivá místa výskytu chyb v signálu v rozdílovém vektoru jednoznačně patrná (výrazné lokální extrémy), pro signály komplikovanější (např. reálný zvukový signál) jsou sice v rozdílovém vektoru patrná místa výskytu chyb, ovšem kromě toho se zde objevuje rozdílový signál daný tím, že neuronová síť ne zcela přesně dokáže detekovat chyby v takto komplikovaném signálu. Ovšem i tento rozdílový vektor postačuje k detekci a lokalizaci chyby v signálu. Původní myšlenkou bylo konkretizaci poruch provést na základě analýzy rozdílového vektoru, tedy přesněji řečeno jednalo by se o systém několika paralelně pracujících neuronových sítí přičemž každá by byla naučena na jednu z uvažovaných chyb (na příznak této chyby v rozdílovém vektoru). Praktické ověření

této metody ovšem ukázalo, že příznaky různých chyb jsou v rozdílovém vektoru v nichž kterých případech velmi podobné a takto navržený systém by nedokázal chyby přesně klasifikovat. Z tohoto důvodu byla zvolena metoda separované chybové části signálu. Neuronové sítě jsou „naučeny“ na průběh všech uvažovaných chyb a síť, která je naučena na chybu, která se v testovaném signálu právě vyskytuje, má nejmenší výstupní celkovou chybu sítě. Celkově lze konstatovat, že mnohdy je jednodušší predikce pomocí MLP sítě velmi optimistická (silná korelace na hodnotu $y(k)$) a je nutno ji doplnit případy víceúrovňových predikcí. Mnohdy ani to nestačí a pro opravdu složitější signály je nutno využít sítě s radiální bázovou funkcí (RBF), jak bylo ukázáno např. v práci [7], anebo aplikovat některý ze speciálních typů sítí (např. z rodiny ART – detaily ve zdroji [2]). Aplikace neuronových sítí v diagnostice je v současné době velmi častá [5], [6] a obtoží ve srovnání klasickými i neklasickými diagnostickými metodami [8], [9], [10].

Pro aplikaci metody v praxi je nutno definovat chyby které chceme systémem detekovat, stanovit signály na kterých se mohou chyby vyskytnout a přizpůsobit navržený systém konkrétním podmínkám. Neuronová síť určená pro lokalizaci chyb bude naučena na bezchybný průběh signálu a neuronové sítě klasifikátoru chyb budou naučeny na jednotlivé uvažované chyby tím, že je možné systém kdykoliv rozšířit o další typy chyb a signálů. Z hlediska technické realizace je nutno především zvolit vhodný simulátor neuronové sítě, který umožní realizaci daného diagnostického systému. Popisovaný systém byl realizován softwarovým simulátorem Neural Network Toolbox v prostředí MatLab/Simulink. Kvalita a citlivost celého diagnostického zařízení je dána především přesností „naučení se“ neuronové sítě na bezchybný průběh signálu, resp. na jednotlivé typy chyb v klasifikátoru chyb.

Lektoroval: Prof. Ing. Jiří Bíla, DrSc.

Předloženo: v březnu 2002.

Literatura

- [1] Bíla, J.: *Umělá inteligence a neuronové sítě v aplikacích*. (2. přepracované vydání). Vydavatelství ĚVUT, Praha (1998).
- [2] Šnorek, M., Jiřina, M.: *Neuronové sítě a neuroplasticita*. ĚVUT, Praha, (1996).
- [3] Drábek, V.: *Spolehlivost a diagnostika*. SNTL, Brno (1983).
- [4] Bíla, J., Kořan, L.: *Application of Matroids in Detection*. In Proc. Of 12th Int. Conference „Process Control 99“, High Tatras, S.R., Vol. 1., (1999) pp. 78-82.
- [5] Bíla, J., Krejčí, M., Houfek, P., Koran, L.: *Neural Networks in Ultrasonic Testing of Thin Walled Welded Constructions used in Aerospace Industry*. In Proc. Of 5th Int. Conference on Soft Computing – MENDEL 99, Brno, C.R., (1999) pp. 325-328.
- [6] Krejčí, M.: *Diagnostické systémy*. Vydavatelství ĚVUT, Praha (1995).
- [7] Vitkaj, J.: *Analysis of Chaotic Signals by means of Nonlinear Methods*. In Proc. Of 4th Int. Conf. on Soft Computing, Brno, C.R., (1998) pp. 296-299.

Michal Musil:

- [8] Lánský, M.: *Teorie automatizovaných diagnostických systémů v dopravě a spojkách*. Nadas, Praha (1990).
- [9] Natke, H.G.: *Einführung in Theorie und Praxis der Zeitreihenanalyse und Modalanalyse*. Vieweg, Wiesbaden (1983).
- [10] Lánský, M.: *Teorie automatizovaných diagnostických systémů v dopravě a spojkách*. Nadas, Praha (1990).
- [11] Patton, R. J.: *Robust model - based fault diagnosis The state of the art, Model - Based Fault Diagnosis*. Zakopane (1994), pages 40 - 60.
- [12] Sedláček, M.: *Zpracování signálů v měřicí technice*. Skriptum ĚVUT, Praha (1993).
- [13] Dalmi, I., Kovács, L., Terstyánszky, G.: *Diagnosing Priori Unknown Faults by Radial Basis Function Neural Network*. Proc. of ECSAP-97 The First European Conference on Signal Analysis and Prediction, Prague, Czech Republik, 24-27 June (1997), s. 228-231.
- [14] Musil, M.: *Diagnostika analogových a číslicových přenosových kanálů*. Sborník prací konference "Současné problémy v kolejových vozidlech", Univerzita Pardubice, (1994).
- [15] Musil, M.: *Aplikace neuronových sítí pro detekci poruch signálů*. Scientific papers of the University Pardubice, Series B, The Jan Perner Transport Faculty, Pardubice (1999) str. 165-174, ISBN-80-7194-283-9, ISSN-1211-6610.
- [16] Kotek, Z., Brůha, I., Chalupa, V., Jelínek, J.: *Adaptivní a učící se systémy*. Praha, SNTL (1980).
- [17] Mudrová, M., Procházka, A., Fiala, J.: *Wavelet use for noise rejection and signal modelling*. Proc. of ECSAP-97 The First European Conference on Signal Analysis and Prediction, Prague, Czech Republik, 24-27 June (1997), s. 247-250.
- [18] Coates, M., Fitzgerald, W.: *Wavelet-based correlation measurement and shift estimation*. Proc. of ECSAP-97 The First European Conference on Signal Analysis and Prediction, Prague, Czech Republik, 24-27 June (1997), s. 238-241.
- [19] Kotsas, P., Strintzis, M., Maglaveras, N.: *Non-Stationary ECG analysis using the Wigner-Ville transform and Wavelets*. Proc. of ECSAP-97 The First European Conference on Signal Analysis and Prediction, Prague, Czech Republik, 24-27 June (1997), s. 399-402.
- [20] Bíla, J., Vitkaj, J.: *Method of Qualitative Analysis of Biosignals by Neural Networks*. Research Report No. 0496, Dep. Of automatic Control, Faculty of Mechanical Engineering, CTU in Prague, (1996).
- [21] Cichocki, A., Cao, J.: *Self-Adaptive Neural Network for On-line Blind Separation of Convolved Sources*. III International Workshop - Advances in Signal processing for NDE of Materials, Quebec, Canada, 5-8 August (1997), s. 207-212.
- [22] Bison, P., Marinetti, S., Manduchi, G., Grinzato, E.: *Improvement of Neural Network performances in Thermal NDE*. III International Workshop - Advances in Signal processing for NDE of Materials, Quebec, Canada, 5-8 August (1997), s. 221-227.
- [23] Štorek, M., Procházka, M.: *Neural Networks in Signal Prediction*. Proc. of ECSAP-97 The First European Conference on Signal Analysis and Prediction, Prague, Czech Republik, 24-27 June (1997), s. 228-231.

Resumé

NÁVRH A REALIZACE KLASIFIKÁTORU CHYB DIAGNOSTICKÉHO SYSTÉMU S VYUŽITÍM NEURONOVÝCH SÍTÍ

Michal MUSIL

Příspěvek se zabývá návrhem, realizací a ověřením účinnosti klasifikátoru chyb diagnostického systému. Hlavním prostředkem pro realizaci klasifikátoru jsou neuronové sítě.

Vpříspevku je popisována detekce, lokalizace a klasifikace chyb vsignálech prostřednictvím neuronových sítí. Je zde vysvětlen princip generování rozdílového vektoru a klasifikace chyb metodou analýzy příznaků v rozdílovém vektoru a metodou analýzy separované chybové části signálu. Tento princip lokalizace a klasifikace poruch je zde uveden na příkladech diagnostiky chyb ve vybraných typech signálů. V závěru příspěvku je zhodnocena účinnost popisovaného klasifikátoru chyb prostřednictvím definovaných kritérií a dále možnosti praktického využití klasifikátoru chyb.

Summary

PROJECT AND REALISATION OF AN ERROR-CLASSIFIER OF A DIAGNOSTIC SYSTEM WITH USE OF NEURAL NETWORKS

Michal MUSIL

This contribution deals with a project, realisation and verification for working of error-classifier of a diagnostic system. The neural networks are the main means for realisation of the classifier. Representative types of the neural networks and their usability for solution of a project of the classifier are mentioned in the introductory part of the paper. Deterministic methods for the classification of errors in the system as well as their mathematical description are given in the next part. Methods of discriminated functions and methods of minimum distance from a standard are presented here.

Diagnostics of an error is divided into the three phases - detection, localisation and classification of the error. First of all, the described system realised by means of the neural networks, performs a detection and localisation of the error - the neural networks are learnt to non-defective course of diagnostic signals and, each defect in the system is displayed as a symptom in the diagnostic signal, the symptom is detected and localised by means of the neural networks. Further more, the part of classification of the error follows, when the separated part of a signal containing this error (symptom of the error) is analysed by means of the error-classifier which is realised with parallel-working neural networks, when each network is learnt to a particular type of the error. The double-learning principle of the neural networks is applied here - first, to the non-defective course of the signal (detection, localisation) and, subsequently to the particular symptoms of errors in the signal (classification).

The neural networks for realisation of the error-classifier are constituted by means of the software products Matlab/Simulink and its Neural Network Toolboxes.

The theoretical introduction gives an account of the particular types of neural networks (Hopfield's network, Kohen's network, ART network and MLP networks) and their application in the given problems. A verification of the operation of the error-classifier for real definite signals is also an integral part of the solution; there will be simulated 16 different errors in the signals here. Real signals from tensometer-analyses (e.g. measuring of force-effects between a railway vehicle and a stretch of rail) as well as real sound-signals will be given as used signals. In this way, we can verify an operation of the proposed classifier in real technical environments with respect to possible application of the diagnostic system, e.g. within practical measurements. Evaluation of the efficiency of the proposed classifier as well as possibility of its extending to the next set of errors is a component of the paper, too.

It is necessary to mention that the described classifier can be applied both for classification of errors in signals obtained e.g. from measurements in system of railway vehicle versus transport route, and for general diagnostic system to analyse diagnostic signals and to classify errors in real diagnostic object. When applying the artificial neural networks to realisation of the error-classifier, much broader possibilities open up for application of the described system and its use in the cases where classical diagnostic methods and aims fall down and do not converge.

The fundamental part of the contribution is aimed at the project, realisation and verification for the operation of the diagnostic system with use of the neural networks for the detection of errors

Michal Musil:

in signals. The survey of the considered errors of a signal and their classification into the particular categories is presented here. Detection, localisation and classification of errors in the signals, is described in the next part. The principle of generation of the differential vector and classification of errors with use of the symptom analysis method in the differential vector, as well as with use of the method of analysis of a separated error part of a signal is explained here. This principle of localisation and classification of errors is elucidated here with use of the examples of diagnostics of errors in representative types of signals. As a practical application, the diagnostics of errors in signals from tensometric measurements as well as from real audio signals is given in the paper. Results relating to the detection and localisation of an error as well as to the classification of the error by means of the neural-classifier are referred here.

The evaluation of an efficiency of the described error-classifier by means of the defined criteria as well as the possibility of the next application of the error-classifier, is mentioned in conclusion.

Zusammenfassung

DER VORSCHLAG UND DIE REALISATION DES KLASSIERERFEHLER DAS DIAGNOSTISCH SYSTEM MIT DIE VERWENDUNG NEURALNETZEN

Michal MUSIL

Beitrag sich betreibt Vorschlag, Realisation und vidiert Aktionen Klassierer Fehler diagnostisch des Systems. Wichtigste Mittel für der Realisation Klassierer sind des Neuralnetze. In Beitrages ist beschreiben Nachweise, Lokalisierung und Klassifikation Fehler in Signal mittelst Neuralnetze . Ist da aufgeschlossen Prinzip Generierung der Differenzvektor und Klassifikation Fehler Methode Analysen Anzeichen in der Differenzvektor und Methode Analysen separieren fehlen Teile Signal. Dieser Prinzip Lokalisierung und Klassifikation Defekten ist da gesetzt zum Beispiel der Diagnostik Fehler in ausgesuchter Typen Signal. In Epilogs Beitrages ist ausgewertet Ausbeute beschreiben Klassierer Fehler mittelst definieren Kriterium und weiter die Möglichkeiten praktisch die Verwendung Klassierer Fehler.