

DIAGNOSTYKA TECHNICZNA – SPOJRZENIE SYNTETYCZNE¹

Czesław CEMPEL

Politechnika Poznańska, ul Piotrowo 3, 60-965 Poznań,
email; czeslaw.cempel@put.poznan.pl

Streszczenie

Diagnostyka techniczna, a pod tym pojęciem rozumiemy diagnostykę maszyn i urządzeń, jako nauka zaczęła się zwolna wyłaniać w latach siedemdziesiątych. Wpiew w dziedzinie tej panowały normy drganiowe typu ISO 1940, lub nawet ustalenia prywatnych firm (*IRD Mechanalysis*) zajmujących się diagnostyką maszyn. A trzeba dodać, że możliwości badawcze procesów drganiowych, i wiedza o drganiach maszyn nie była wtedy duża. Mierzono amplitudy drgań prędkości, przemieszenia, czy też przyspieszenia, za pomocą dość prostych przetworników, rejestratorów i analizatorów. Ale stopniowo łącząc tę wiedzę z podstawami dynamiki maszyn i wibroakustyki maszyn modelami i relacjami udało się ze 'sztuki pomiaru i interpretacji', jaką była wtedy diagnostyka, zrobić 'prawie' dyscyplinę wiedzy i umiejętności, niezwykle przydatną w praktyce utrzymania ruchu maszyn. Przyczyniły się do tego znacznie hardwarowe i softwarowe postępy w przetwarzaniu sygnałów i rosnące powiązanie tej wiedzy szczególnie z dynamiką i eksploatacją maszyn, ze sposobem ich zużywania się i wyłaniającymi się zwolna modelami diagnostycznymi, technologiami informatycznymi i sztuczną inteligencją.

W chwili obecnej metody i środki diagnostyki technicznej, zwłaszcza wibroakustycznej, znalazły zastosowanie we wszystkich fazach życia obiektów, od projektowania przez wytwarzanie, eksploatację, aż do reużytkowania. W pracy będą scharakteryzowane głównie sposoby rozumowania i osiągnięcia diagnostyki, a w sposób zwarty najlepiej to ilustruje załączona w podsumowaniu mapka myślowa.

MACHINE CONDITION MONITORING – HISTORIC OVERVIEW

Summary

The beginning of machine condition monitoring (MCM) starts in a half of a previous century, mainly as a help in critical machines maintenance. At that time, the knowledge on machine acoustic noise and vibration was not large, mainly due to small possibilities in measuring and analysis of these processes. Hence it was based mainly on application of some vibration standards like ISO 1940, and the guidelines of some consulting firms like *IRD Mechanalysis*. The accumulation of knowledge on vibrational behavior of machines and improvements in measuring and analysis of vibration signals, mainly due to introduction of digital signal processing and analysis, has made substantial increase in machine fault detection and condition forecasting. Moreover vibration condition monitoring of the machines is now applied not only to the running machines, but in all phases of machine life, in the design, manufacturing, the usage, and recycling. We can measure, process and use for these purposes several vibration processes simultaneously, enabling the precise fault detection assessment and forecasting of residual life of the machine, sometimes far away from the machines, like in case of large wind turbines and farms.

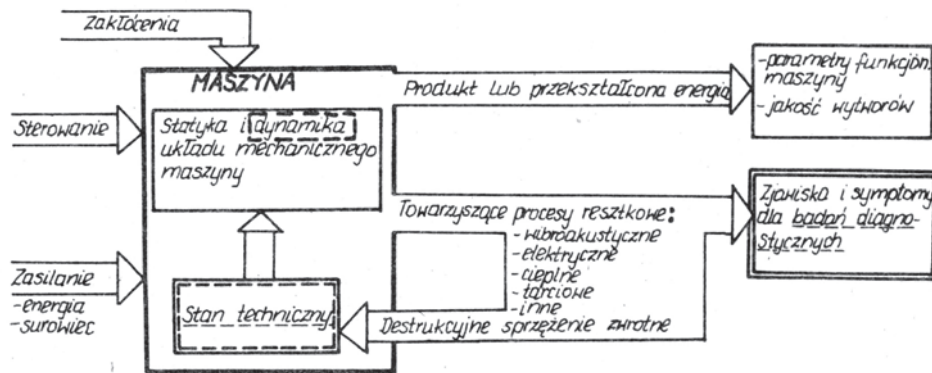
Key words: vibration condition monitoring, historical overview, signal generation models, symptom life time models, multidimensional symptom processing.

1. WSTĘP

Oddalenie człowieka operatora od indywidualnej maszyny, stopniowe grupowanie maszyn we wzajemnie zależne ciągi technologiczne, zaczęło narastać od początku wieku 20tego. Stało się to przyczyną odcięcia wiedzy o stanie konkretnej maszyny od człowieka operatora, odpowiedzialnego za stan produkcji, oraz stan i ekonomię przedsiębiorstwa. Najwcześniej i najbardziej dotkliwie dało się to we znaki dla maszyn² i systemów technicznych, które spełniła krytyczną funkcję w systemie, takich jak np. turbogeneratory silniki napędowe w przemyśle i w transporcie. Tutaj najwcześniej zaczęła się rodzić i kumulować wiedza o sposobach i procesach

zużywania³ się obiektów i o symptomach⁴ towarzyszących procesowi zużywania się. Warto na te procesy spojrzeć z szerszego punktu widzenia, jeśli maszynę potraktujemy jako system działaniowy zgodnie z ideą rysunku 1.

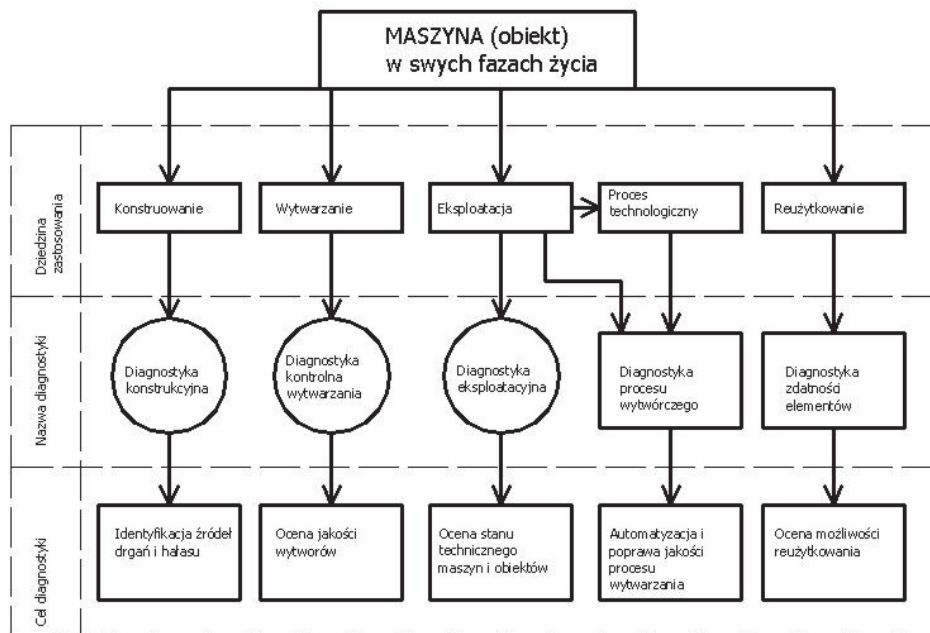
1. Tekst główny to referat zamawiany na 56 Konferencję Inżynierów Budownictwa, Krynica, wrzesień 2010.
2. Będziemy zamiennie używać pojęcia; maszyna, obiekt, system techniczny, itp. zależnie od szczegółowego kontekstu.
3. Procesy zużyciowe w maszynach można z grubsza podzielić na; zmęczeniowe, tarciove i erozyjne.
4. Symptom, wielkość obserwowalna i mierzalna współmiennicza ze stanem obiektu.



Rys.1. Maszyna jak system działaniowy z przepływem energii i informacji oraz możliwości jej obserwacji diagnostyczne [1]

Jak widać z rysunku wszystkie wyjścia maszyny niosą informację o jej **stanie technicznym**⁵ (zużyciowym), lecz nie wszystkie obserwowane procesy są jednakowo dogodne do obserwacji diagnostycznej, lub niosą ten sam zasób informacji diagnostycznej. Jak się okazuje, największy zasób informacji o stanie niosą procesy dynamiczne, takie jak drgania, dźwięk (*hałas*), które łatwo przekształcić

w **sygnaly**⁶ do dalszej obróbki informacji diagnostycznej. Stąd też procesy wibroakustyczne (WA) maszyn najwcześniej (*lata 60te i 70te ubiegłego wieku*) zaczęto używać do diagnostyki stanu maszyn [16, 17], ale nie tylko jak to widać z kolejnego rysunku 2.



Rys.2. Syntetyczne ujęcie celów i rodzajów diagnostyki wibroakustycznej w przemyśle (w ślad za [1] ze zmianami)

Obserwując procesy WA już w procesie konstruowania i badań prototypu, możemy dowiedzieć się jak poprawić jakość dynamiczną konstrukcji, co później odzwierciedli się w jej charakterystykach zużyciowych, trwałościowych i niezawodnościowych. Widać również z rysunku 2, że diagnostyka towarzyszy każdej fazie cyklu życia maszyny, nawet w reużytkowaniu podzespołów i/lub elementów i materiałów.

Najważniejsze jednak miejsce we wszystkich rodzajach diagnostyki przypada w udziale diagnostyce eksploatacyjnej, gdyż od niej zależy

efektywność transformacji zaangażowanych zasobów, a przede wszystkim bezpieczeństwo coraz bardziej skomplikowanych maszyn i systemów technosfery. Stąd też gros wysiłku badawczego i wdrożeniowego jest zawsze kierowane w tę stronę zastosowań diagnostyki.

5. Stan techniczny odzwierciedla zaawansowanie procesów zużyciowych w obiekcie.

6. Sygnal, wielkość szybkozmienna będąca informacyjnym odwzorowaniem dynamicznego procesu zachodzącego w obiekcie.

2. EWOLUCJA STANU TECHNICZNEGO MASZYN, USZKODZENIA, SYMPTOMY SYGNAŁY

Ewolucja ta zachodzi podczas użytkowania, czyli tzw. eksploatacji maszyn, obiektów i szerzej mówiąc systemów. Siła napędową tej ewolucji stanu są procesy robocze zachodzące w maszynie, zaś jej źródłem są początkowe niesprawności tkwiące w materiale (*defekty struktury, dyslokacje, itd.*), w wykonaniu (*tolerowane niewyrównowazenie*) i dopasowaniu elementów (*tolerowana nieosiowość*), itp. Początkowo, dla czasu życia⁷ obiektu $\theta \approx 0$ uszkodzenia te rozwijają się niezależnie, a ponieważ jest to na ogół nie pojedyncze uszkodzenie oznaczmy je jako:

$$F_i(\theta), \quad 0 < \theta < \theta_b; \quad i=1\dots t, \quad (1)$$

gdzie θ_b czas życia elementu i/lub obiektu.

W miarę ich rozwoju niektóre z uszkodzeń, pobierając energie z ruchu roboczego, zaczynają dominować napędzając rozwój pozostałych przez drgania, stając się pod koniec życia systemu coraz bardziej współzależne dając tzw. syndrom starego człowieka [1]. Relacja (1) definiuje nam tzw. przestrzeń uszkodzeń U naszego obiektu, i jak widać jest ona zawsze wielowymiarowa rozwijająca się z czasem θ , przy czym jak łatwo się domyślić nie wszystkie uszkodzenia F_i muszą być zauważalne dla $\theta \approx 0$, ich szybkość narastania $dF_i/d\theta$ może być różnorodna, nawet niewspółmierna. Zatem do pewnych celów może być potrzebna zbiorcza miara zaawansowania wszystkich uszkodzeń

w naszym obiekcie w danej chwili czasu θ , np. w postaci tzw. kumulanty uszkodzeń

$$F(\theta) = \sum^t F_i(\theta), \text{ lub też: } F(\theta) = \sum^t w_i F_i(\theta), \quad (2)$$


z wagami w_i unormowanymi do jedności. Uszkodzenia te mają swoje wibroakustyczne sygnatury $v_i(t, \theta)$, będące ich dynamiczną transformacją poprzez ruch roboczy w maszynie i czas dynamiczny t , w miejscu powstania uszkodzenia o współrzędnej wektorowej r_i . Możemy więc napisać transformację dynamiczną uszkodzenia w sygnał:

$$F_i(\theta) \Rightarrow v_i(t, \theta, r_i); \quad (3)$$

Jeśli przypomnimy sobie, że każda struktura mechaniczna może być scharakteryzowana zbiorem charakterystyk impulsowych $h_i(t, \theta, r_i)$ możliwych do poznania przez identyfikację [8], to sygnał odbierany przez przetwornik drganiowy w określonym miejscu r może być wyrażony jako suma sygnałów od uszkodzeń pierwotnych F_i , ruchu roboczego obiektu i zakłóceń, zgodnie z rysunkiem 3, jak niżej.

$$S(r, t, \theta) = \sum^t h_i(t, \theta, r_i) * v_i(t, \theta, r_i) + c(t, \theta, r) + n(t, \theta, r), \quad (4)$$

gdzie $c(t, \theta, r)$ jest tzw. sygnałem znamionowym (*pracy*) obiektu, natomiast $n(t, \theta, r)$ jest szumem generowanym w pracującym obiekcie, oznaczenie * symbolizuje splot dynamiczny (t) odpowiedzi impulsowej i sygnału charakterystycznego uszkodzenia.



Rys. 3. Model obserwacji diagnostycznej struktury maszyny [1]

Jak widać z (4) model sygnału wibroakustycznego pracującej maszyny z uszkodzeniami nie jest taki prosty i ekstrakcja informacji diagnostycznej może nie być łatwa, choćby z tytułu dominacji sygnału znamionowego pracy obiektu $c(\cdot)$, czy też dużej składowej szumowej $n(\cdot)$ panującej w miejscu odbioru r . Zatem mamy dwie składowe zakłóceniami i jedną składową informacyjną będącą sumą odpowiedzi dynamicznych kilku uszkodzeń. Jeśli więc

przykładowo szukamy sygnału uszkodzenia F_3 to sygnały pozostałych uszkodzeń też odgrywają rolę zakłóceń i muszą być minimalizowane za pomocą odpowiedniej procedury uogólnionej filtracji, o czym bardziej szczegółowo w następnym punkcie.

7. Czas życia obiektu θ , wielkość wolnozmiennej o wymiarze czasu, mierzona w dniach, tygodniach, miesiącach, latach, zależnie od intensywności procesów zużyciowych w obiekcie.

3. SELEKCJA SYGNAŁÓW, ICH MIARY – SYMPTOMY

W czasach analogowej obróbki sygnałów, dominującej prawie do końca wieku 20tego, wiele trzeba się było natrudzić koncepcyjnie i instrumentalnie by dokonać odpowiedniej ekstrakcji sygnałów. Bowiem jak wynika z (4) mamy tu cztery dziedziny do uogólnionej filtracji informacji diagnostycznej; dziedzinę amplitudy $S(\cdot)$, dziedzinę czasu dynamicznego t , dziedzinę czasu życia θ , oraz dziedzinę lokalizacji punktu odbioru r . W tych dziedzinach możemy poszukiwać największego ilorazu stosunku sygnału do szumu dla relacji (4), który w zagadnieniach przetwarzania informacji jest zawsze pierwszoplanowy.

W badaniach diagnostycznych sygnałów maszyn zawsze dysponujemy pewną wstępną wiedzą, która mówi nam, że poszukując określonego uszkodzenia największy stosunek sygnału do szumu uzyskamy w określonym miejscu r korpusu maszyny, bądź obudowy łożyska. Jeśli do tego mamy kierunkowe przetworniki drgań, to również mamy wstępną wiedzę czy obserwować drgania osiowe czy też w kierunku radialnym. Zatem optymalizacja miejsca odbioru w dziedzinie r jest jakoby już przesądzona. Podobnie większość badań procesów WA i stowarzyszonych sygnałów WA jak w (4) wykonuje się dla ustalonego $\theta = \theta_p$, zatem w dalszych rozważaniach sygnału (4) możemy czasem opuścić notacje tych dwu zmiennych pisząc jedynie oznaczenie sygnału jedynie zależnego od czasu, lub obu czasów zależnie od potrzeb;

$$\mathbf{S}(r, t, \theta)^r = \mathbf{s}(t, \theta) \quad (5)$$

Dla tak zapisanego sygnału WA jak w (5), łatwiej będzie przedstawić zagadnienie filtracji w pozostałych trzech dziedzinach amplitudy, czasu dynamicznego i częstości. Wpierw jednak zdefiniujemy miary amplitudy sygnału. Ponieważ obserwowane procesy i uzyskane sygnały zawierają część szumową, przypadkową nie są więc procesami deterministycznymi, a przypadkowymi, probabilistycznymi. Zatem ich miary powinniśmy definiować po zbiorze obserwacji, jako momenty statystyczne procesu, ale jeśli założyć ergodyczność procesów [7] to średnią po zbiorze możemy zastąpić średnią po czasie obserwacji (T) z operatorem uśredniania $E_t(\cdot)$. Zatem uogólniona miarę procesu $\mathbf{s}(t)$ możemy wyrazić jak niżej;

$$s_q(\theta) = E_t(\mathbf{s}) = \left| \frac{1}{T} \int_0^T |\mathbf{s}(t, \theta) dt|^q dt \right|^{1/q},$$

$$q=1,2,3,4; \quad (6)$$

gdzie q jest rzędem momentu statystycznego i dla pierwszych całkowitych wartości istnieje dobra fizyczna interpretacja; dla $q=1$ mamy amplitudę średnią procesu, $q=2$ średniokwadratowa (*rms*) amplituda często nazywana też miarą energetyczną, a dla $q=\infty$ mamy tzw. amplitudę szczytową (*peak*)

procesu (*sygnału*). Najczęściej w badaniach diagnostycznych używamy jako symptomu stanu amplitudy *rms* ($s_q = s_{rms}$), ale przy badaniach niektórych elementów maszyn, np. łożysk tocznych, amplitudy szczytowe są dobrym symptomem ich stanu technicznego.

Będąc w dziedzinie amplitudy procesów i sygnałów diagnostycznych przywołajmy ich charakterystyki amplitudowe; histogram amplitudowy jako funkcja częstości występowania w zadanym przedziale amplitudowym, skąd w podejściu granicznym uzyskamy gęstość prawdopodobieństwa **rozkładu amplitud $p(s)$** i prawdopodobieństwo występowania amplitudy s , czyli $\mathbf{P}(s)$, [6] jako

$$\mathbf{P}(s) = \int_{-\infty}^s p(s_c) ds_c, \quad \text{przy warunku,}$$

$$\int_{-\infty}^{\infty} p(s_c) ds_c = 1. \quad (7)$$


Znajomość rozkładu amplitudowego sygnałów, czy też symptomów, jest często pomocna w diagnostyce, np. uszkodzone łożyska toczne generują nie gaussowskie sygnały, a histogramy symptomów w populacji monitorowanych maszyn są też nie gaussowskie, na ogół **prawoskośne**.

Wkraczając do dziedziny czasu dynamicznego t sygnałów przywołajmy od razu dziedzinę sprzężoną przez transformację Fouriera, czyli dziedzinę częstości f (Hz), która ma doskonałe przełożenie na zakresy częstości drgań i hałasu maszyn. Widmo fourierowskie sygnału jest zdefiniowane następująco [7];

$$\mathbf{S}(f, \theta) = \int_{-\infty}^{\infty} \mathbf{s}(t, \theta) \exp(-i2\pi f \cdot t) dt \quad (8)$$

A wraz z upowszechnieniem cyfrowego przetwarzania sygnałów (*digitalizacja czasu-próbkowanie, kwantyzacja amplitudy*), ta zasadnicza definicja ma cały szereg cyfrowych implementacji, np. widmo krótkoczasowe (*transformata krótkoczasowa*), itp. Jeśli teraz widmo sygnału przemnożymy przez dodatnio zdefiniowaną funkcję; $U(f) > 0$ dla $0 < f < \infty$, to w ten sposób zdefiniowaliśmy **filtr częstościowy**, który z całego sygnału pozwala wyciąć interesujący nas zakres częstości przydatny diagnostycznie, np. składowa obrotowa potrzebna do oceny wyrównoważenia, bądź też pasmo częstości wysokich używane do oceny łożysk tocznych. Można również definiować filtry równoważne do uśredniania synchronicznego, zgodnego z obrotami interesującego nas elementu maszyny, co oddaje nieocenione usługi w diagnostyce maszyn wirnikowych, przekładni, itp.

Analiza fourierowska, często zwana **analiza widmowa** dała inny wymiar i potencję diagnostyce maszyn, wymiar rozwijających się uszkodzeń. Dobra ilustracja tych właściwości daje rysunek 4 zaczerpnięty z [1].



Rys.4. Ilustracja idei diagnostyki drganiowej maszyn prostych przez pomiar amplitudy całkowitej prędkości drgań i analizę widmową sygnału prędkości dla oceny zawansowania różnych defektów, w różnych czasach życia θ , [1]


Rysunek jest prawie samowyjaśniający, ale zwróćmy uwagę na zaznaczoną tam dodatkową możliwość oceny **resztkowego czasu życia** maszyny $\Delta\theta_a$. Oczywiście pod warunkiem że mamy pewne doświadczenie eksploatacyjne i nie obserwujemy tej maszyny pierwszy raz, albo też posiadamy symptomowy model diagnostyczny danej maszyny, o czym jeszcze będziemy mówić.

4. EWOLUCJA I OCENA STANU

Przypatrując się lepiej ostatniemu rysunkowi widzimy, że istotą zużywania się maszyn jest narastanie uszkodzeń / defektów cząstkowych F_i , o czym mówiliśmy już na samym początku definiując je w relacji (1). Jak widać te uszkodzenia mają charakter pierwotny, gdyż ich obecność i zaawansowanie generują tu odpowiedni prążek widmowy w amplitudzie prędkości drgań. Często mają one również charakterystykę wymiarowa, możliwą do

określenia w specjalnych testach przeprowadzanych po wyłączeniu maszyny z ruchu. My jednak bazując na idei rysunku 4 nie zamierzamy wyłączać maszyny z ruchu, a całość wnioskowania diagnostycznego, dotyczącego rodzaju uszkodzenia, jego zaawansowania i możliwej **wartości granicznej** symptomu S_1 otrzymać w trakcie monitorowania maszyny w procesie produkcyjnym.

Kluczowym pojęciem w tym względzie jest krzywa życia, czyli przebieg obserwowanego symptomu w skali życia maszyny, taka pogrubiona krzywa na rysunku 4. Wyobraźmy sobie teraz że prowadzimy eksperyment czynny z populacją kilkudziesięciu maszyn uruchomionych od stanu nowego $\theta = 0$ aż do ich awarii czyli $\theta = \theta_a$, monitorując przy tym w ustalonych odstępach czasu $\Delta\theta$ i ustalonych warunkach symptomu stanu $S(\theta)$. Uzyskamy wtedy gęstwinę punktów pomiarowych, które można przekształcić na odpowiednie histogramy symptomowe tak jak na rysunku 5, [1].



Rys. 5 Statystyczna krzywa życia symptomu jako rezultat eksperymentu czynnego na populacji maszyn i wynikowe histogramy symptomów w różnych stanach [1]

Jak widać z rysunku cztery histogramy pośrednie, początkowej wartości symptomu $p(s_0)$, rozkładu czasu awarii $p(t_a)$, rozkładu symptomu awarii $p(s_a)$, możemy w pierwszym podejściu uznać za symetryczne i nawet gaussowskie. W związku z tym możemy wyznaczyć wartość graniczną symptomu S_1 dopuszczalną w eksploatacji przy założonym procencie możliwych awarii. Gdybyśmy przyjęli $S_1 = S_a$ to z własności rozkładu gaussowskiego można statystycznie przyjąć połowa maszyn uległa by awarii, natomiast tylko 16% dla

$$S_1 = S_a - \sigma_a \quad (9)$$

i taka wartość graniczną możemy przyjąć w pierwszym przybliżeniu, udokładniając ją w miarę nabywania doświadczeń eksploatacyjnych i polityki remontowej parku maszynowego.

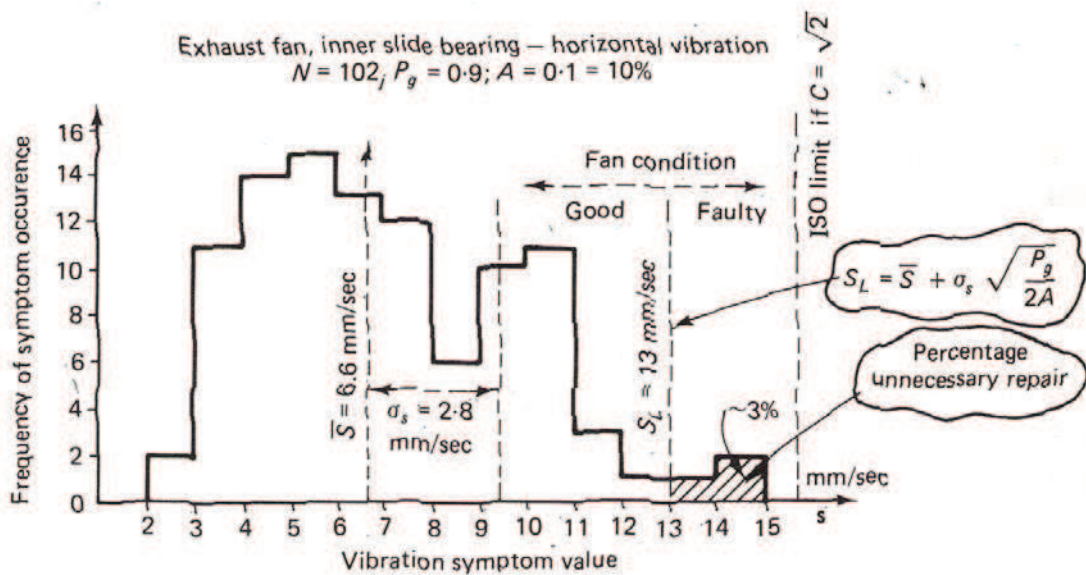
Jest to dość grube przybliżenie wartości granicznej S_1 , a czy można je udokładnić podpierając się modelem czy teorią? Okazuje się że tak, jeśli wykorzystać definicje niezawodności symptomowej $R(S)$, [8], [9], i posłużyć się **regułą Neymana-Pearsona** zaczerpniętą z teorii decyzji statystycznych [5]. Pojęcie niezawodności symptomowej zdefiniowano w [1], a w całej oprawie matematycznej w [9]. Natomiast reguła Neymana-Pearsona, zdefiniowana pierwotnie do wykrywania błędnych odczytów radarowych, zinterpretowana diagnostycznie

wymaga znajomości gotowości $G \leq 1$ grupy eksploatowanych obiektów i określenia dopuszczalnego prawdopodobieństwa zbędnych remontów maszyn $A \ll 1$, np. $A = 0.05\%$. Wtedy wartość graniczna symptomu S_1 wyznaczmy z wzoru [8, 9];

$$G \cdot R(S_1) = A \quad (10)$$

Można to zrobić numerycznie⁸, graficznie na histogramie symptomowym jak na rysunku 6, lub analitycznie, jeśli dysponujemy modelem symptomowym niezawodności [8 tab.2.2].

8. Patrz oprogramowanie użyte później w pracy.



Rys.6. Przykład wyznaczania wartości granicznej symptomu drganiowego maszyn na podstawie histogramu danych nadzoru [3]

Mówiąc o ewolucji stanu maszyn warto skrótkowo zreferować tu koncepcje maszyny jako procesora energii. A idea tak ma poparcie w głębszej analizie rysunku 1. Z punktu widzenia zużyciowego mamy tam wejście energii i/lub zasilania surowcowego, wyjście produktu użytecznego lub przekształconej energii i strumień dyssypowanej energii zewnątrz i wewnątrz. Dyssypacja wewnętrzna jest bardzo mała (*procesy zużyciowe*), lecz ma charakter kumulacyjny i wyczerpuje stopniowo **zapas życia** maszyny. Koncepcja ta przedstawiona jest na rysunku 7, gdzie uzewnętrzniono również cały szereg destrukcyjnych sprzężeń zwrotnych, sterowanych zaawansowaniem zużycia wewnątrz maszyny.

Sam procesor energii może służyć jako model wielu systemów z przetwarzaniem energii, nawet do modelowania organizacji gospodarczej z procesem inwestycyjnym, z ograniczeniem produkcji i zasilania na skutek starzenia [10]. Do naszych celów weźmy jedynie pod uwagę pierwsze sprzężenie, gdzie zakumulowana energia destrukcji E_d steruje w dodatnim sprzężeniu zwrotnym dyssypacją zewnętrzną V , (*im maszyna bardziej zużyta tym więcej wibruje, grzeje się i ma gorsze osiągi*). Jeśli rozważyć stronę analityczną modelu procesora energii to przy najprostszych założeniach [11] otrzymamy rozwiązanie na energię dyssypowaną zewnątrz w postaci;

$$V(\theta) = V_0 \left(1 - \frac{\theta}{\theta_a}\right)^{(-1)}. \quad (11)$$


Wprowadzając teraz do rozważań operator symptomowy⁹ $S = \Phi(V)$, to w zależności od formy operatora (*potęgowej, logarymicznej, itp.*), uzyskamy symptomowe krzywe życia $S(\theta)$, i niezawodności symptomowe $R(S)$ dla różnych modeli statystycznych

populacji obiektów o różnych modelach zużycia; typu **Weibull, Pareto, Frechet** [8, tab.2.2]. Najprostszy, potęgowy i jednoparametrowy model Pareto daje relacje diagnostyczne postaci;

$$S(\theta) = S_0 \left(1 - \frac{\theta}{\theta_a}\right)^{(-\gamma)}, \text{ oraz } R(S) = \left[\frac{S}{S_0}\right]^{-\gamma} \quad (12)$$

Z eksperymentu biernego (*lub czynnego*) na populacji monitorowanych maszyn można wyznaczyć parametr rozkładu symptomu γ , wtedy zagadnienie prognozowania następnej wartości symptomu $S(\theta_{n+1})$, lub resztkowego czasu do awarii $\Delta\theta_a$, bądź wyznaczanie wartości granicznej S_1 (z uwzględnieniem (10)) jest łatwo rozwiązywalne.

9. Ta sama energia dyssypowana daje różne efekty w procesach resztkowych, zależnie konstrukcji maszyny jak i jej procesów roboczych. Stąd wprowadzono pojęcie operatora symptomowego.



Rys.7. Maszyna jako procesor energii z dyssypacją i destrukcyjnymi sprzężeniami zwrotnymi[10]

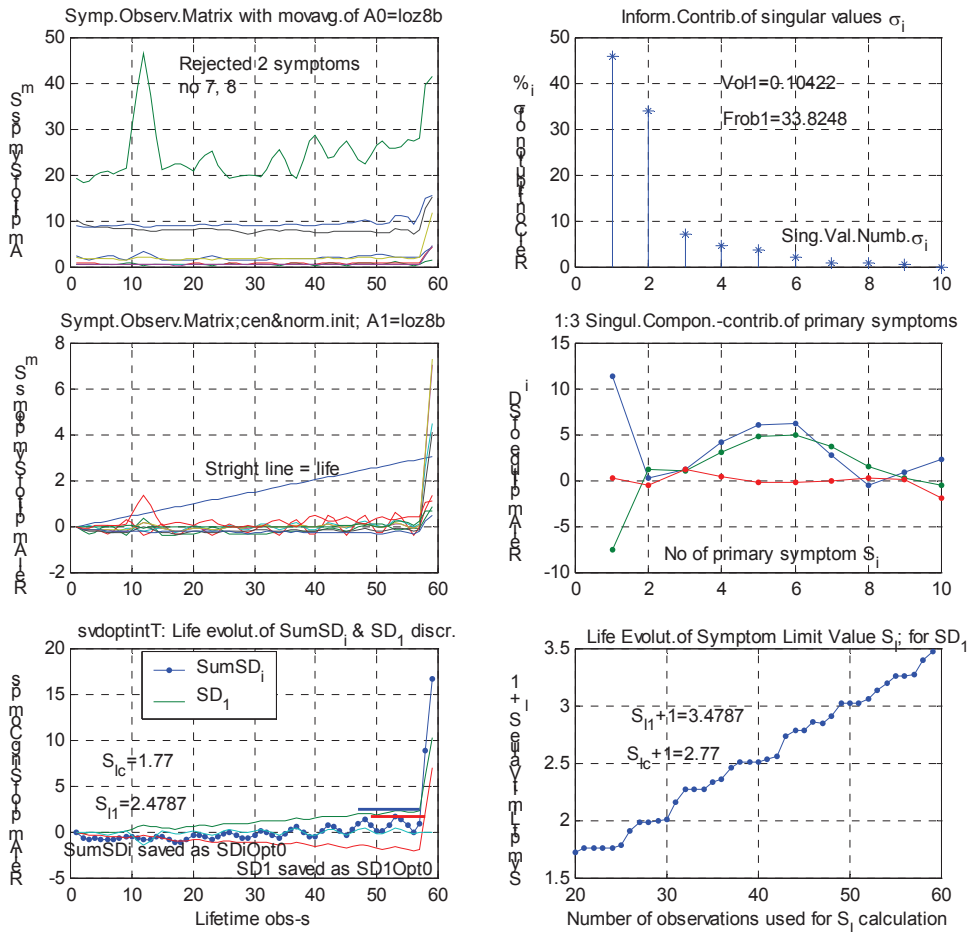
5. DIAGNOSTYKA WIELOWYMIAROWA I WIELOSYMPTOMOWA

We wstępie zasygnalizowano już, że w maszynie rozwija się współbieżnie wiele uszkodzeń, a rysunek 4 pokazuje, że stosując dodatkowe metody analizy i przetwarzania sygnałów można je wykryć i ocenić z jednego obserwowanego sygnału. Współczesne systemy pomiarowe umożliwiają jednoczesną obserwację wielu procesów i jednoczesne utworzenie z nich jeszcze większej liczby symptomów. Mamy zatem możliwość stworzenia i wykorzystania wielowymiarowej przestrzeni obserwacji $S_j(\theta)$, by następnie rzutować zebraną informację na przestrzeń uszkodzeń obiektu $F_i(\theta)$.

Nasze zadanie wielowymiarowej diagnostyki wygląda obecnie jak niżej. Obserwujemy zbiór symptomów; $S_j(\theta)$, $j=1\dots r$, w odstępach czasu życia $\Delta\theta$, tworząc ciąg odczytów symptomów; $n=1\dots m$. Stworzyliśmy w ten sposób symptomowa macierz obserwacji (SMO) o r symptomowych kolumnach i m wierszach odczytów, przy czym na ogół $m > r$ i mamy prostokątną SMO. Natura symptomów jest na ogół różna fizycznie, bo to może być czas życia, obiektu w tygodniach, amplitudy drgań przemieszczeń, prędkości, przyspieszeń, poziom hałasu w dB, moc napędowa lub moment obrotowy silnika, itd. Zatem, konieczny jest wstępny pre-processing SMO, a potem

dopiero ekstrakcja informacji diagnostycznej za pomocą jednej z metod obróbki macierzy prostokątnych. Wchodzą tu w grę dwie metody; principal component analysis (PCA) i singular value decomposition (SVD). Pierwsza jest bardzo popularna, zwłaszcza w psychologii matematycznej, ale niestety operuje na iloczynnie SMO z jej wersją transponowaną, natomiast druga operuje wprost na SMO wyzbywając się niedogodności pierwszej i dlatego w diagnostyce jest preferowana przez obecnego autora.

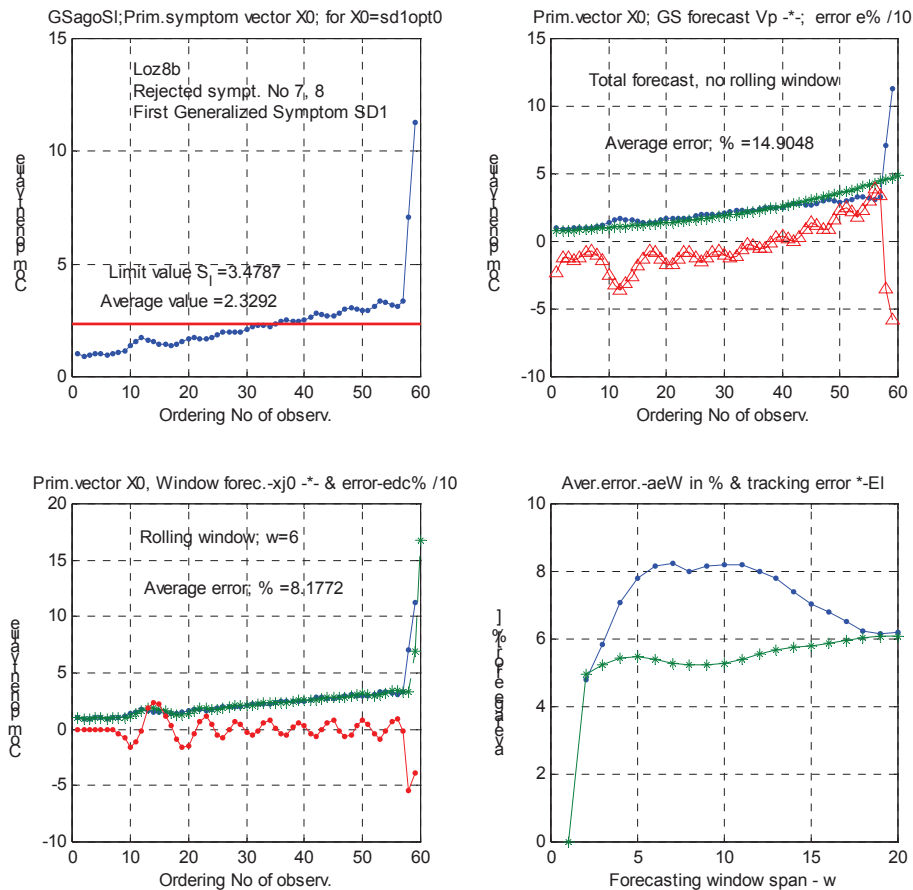
Na kolejnych dwu rysunkach przedstawione są rezultaty obliczeń oprogramowania opartego o zreferowane wyżej rezultaty detekcji uszkodzeń i ich oceny diagnostycznej. Ostatni zaś rysunek pokazuje rezultaty prognozy w oparciu o najnowsza chińską metodę; **grey system theory** (GST), [13, 14] stosowaną w wielu dziedzinach nauki i gospodarki w wypadkach, kiedy mamy niewiele i do tego niepewnych danych z badań. A taka właśnie sytuacja zachodzi często w diagnostycznej ocenie maszyn. Oceniany obiekt (rys.8) to wentylatorowy młyn węglowy pracujący w Poznańskiej Elektrociepłowni Karolin, na którym mierzono skuteczną prędkość drgań V_{rms} w 11tu punktach pomiarowych na korpusie maszyny przez okres prawie 60 tygodni ($\Delta\theta = 1$ tydzień).



Rys. 8. Efekt wielowymiarowego przetwarzania SMO młyna wentylatorowego metoda SVD [12]

Obrazek górny lewy rysunku 8 przedstawia SMO tak jak została zanotowana w cotygodniowych pomiarach w 11 tu punktach, przez prawie 60 tygodni, a lewy środkowy obrazek przedstawia tę samą SOM po pre-procesingu, tzn. po normalizacji do wartości początkowej i po odjęciu tej wartości od odczytów każdej kolumny. Dodano tu również nowy symptom, czas życia maszyny, co widać w postaci wznoszącej linii prostej. Jak widać po normalizacji niewiele się dzieje w sensie zmiany stanu i dopiero kilka ostatnich odczytów może ewentualnie na to wskazywać, co już znacznie lepiej widać po zastosowaniu SVD, na obrazku lewym dolnym. Na obrazku tym również zaznaczono wartości graniczne uogólnionych symptomów wyznaczone metodą niezawodności

symptomowej (obrazek prawy dolny). Obrazek środkowy prawy pokazuje zawartość informacji, jakie niosą poszczególne symptomy mierzone pierwotnie i służy do informacyjnej optymalizacji SMO. Jak zaznaczono na obrazku górnym prawym, wstępnie odrzucono już dwa symptomy, a z analizy obrazka lewego środkowego wynika, że mamy jeszcze kilka kandydatów do odrzucenia w następnym kroku optymalizacji. Wreszcie obrazek górny prawy pokazuje zawartość informacji o poszczególnych uszkodzeniach w SMO i widać, że na czas wyłączenia wentylatora rozwinęły się dostatecznie dwa uszkodzenia; niewyrównoważenie wirnika i jedno z jego łożysk.



Rys. 9. Prognoza stanu młyna dla symptomu pierwszego uszkodzenia (SD1) metodą GST z ruchomym okienkiem prognozowania i bez okienka, [12]

Prognozę przyszłej wartości symptomu pierwszego uszkodzenia SD1, rysunek 9, wykonano chińska metodą Grey System Theory [np. 13, 14] zaadoptowaną niedawno do celów diagnostyki. Obrazek górny prawy pokazuje tu symptom pierwszego uogólnionego uszkodzenia SD1, wraz z odpowiednimi wartościami granicznymi S_1 i wartością średnia. Pozostałe obrazki są samo wyjaśniające i widać z nich że prognoza okienkowa GST daje mniejsze błędy niż prognoza ze wszystkimi wynikami odczytu. Widać też dalej, że manipulując szerokością okna w można minimalizować błąd prognozy (obrazek prawy dolny).

6. NOWE KIERUNKI W DIAGNOSTYCE MASZYN

Jak to zwykle bywa w jedno autorskich pracach przeglądowych trudno znaleźć miejsce na referowanie dokonań innych autorów. Dobrze się jednak składa, że społeczność diagnostyki maszyn przygotowała już dwa poradniki [3,4], w których można znaleźć kompendium wiedzy krajowych autorów, również dobrze zapoznanych w nauce światowej. Dlatego też wiele nowych trendów w badaniach można znaleźć w najnowszym poradniku [4], w szczególności

w rozdziałach dotyczących sztucznej inteligencji (R.22) i technologii informatycznych w diagnostyce (R.23), gdzie rozwija się szerzej nowe koncepcje inteligentnych systemów diagnostycznych, oraz metodologii pozyskiwania wiedzy diagnostycznej.

Najnowszym dzieckiem diagnostyki maszyn jest diagnostyka konstrukcji (*SHM – Structural Health Monitoring*) gdzie stosuje się najnowsze zdobycze nauki, metrologii, technologii informatycznych, a układy nadzoru są zwykle zintegrowane z konstrukcją, a mówi się już o układach samo diagnozujących i samo naprawczych (patrz np. prace W. Staszewskiego i W. Ostachowicza).

Gałęzią boczna diagnostyki maszyn, która zaczyna już dojrzeć metodologicznie, jest **diagnostyka procesów**. By się o tym przekonać warto skonsultować pierwszy poradnik w tej dziedzinie [18]. W skrócie mówiąc jest to diagnostyka ukierunkowana na procesy wytwarzania zwłaszcza przemysłu chemicznego i jest silnie skojarzona z automatyczną regulacją tych procesów. Jest tam również miejsce na liczące się zastosowania sztucznej inteligencji i technologii informatycznych.

Ostatnia i najświeższą nowinką warta wspomnienia w tym bardzo skrótowym przeglądzie jest **diagnostyka wirtualna**, gdzie obrazowo mówiąc zamiast pytać maszynę o „samopoczucie i zdrowie” odpytuje się jej model odpowiednio skomplikowany. Model taki musi ujmować nie tylko stronę funkcjonalną systemu, ale również posiadać wielowariantowe modele procesów zużyciowych obiektu. Nie jest to takie proste, bo oprócz stosownej bazy wiedzy trzeba mieć stosowne oprogramowanie, które jest zdolne uchwycić te wielowariantowość. Przykładem wczesnych zastosowań diagnostyki wirtualnej są badania komfortu jazdy samochodu KIA na różnych drogach [15].

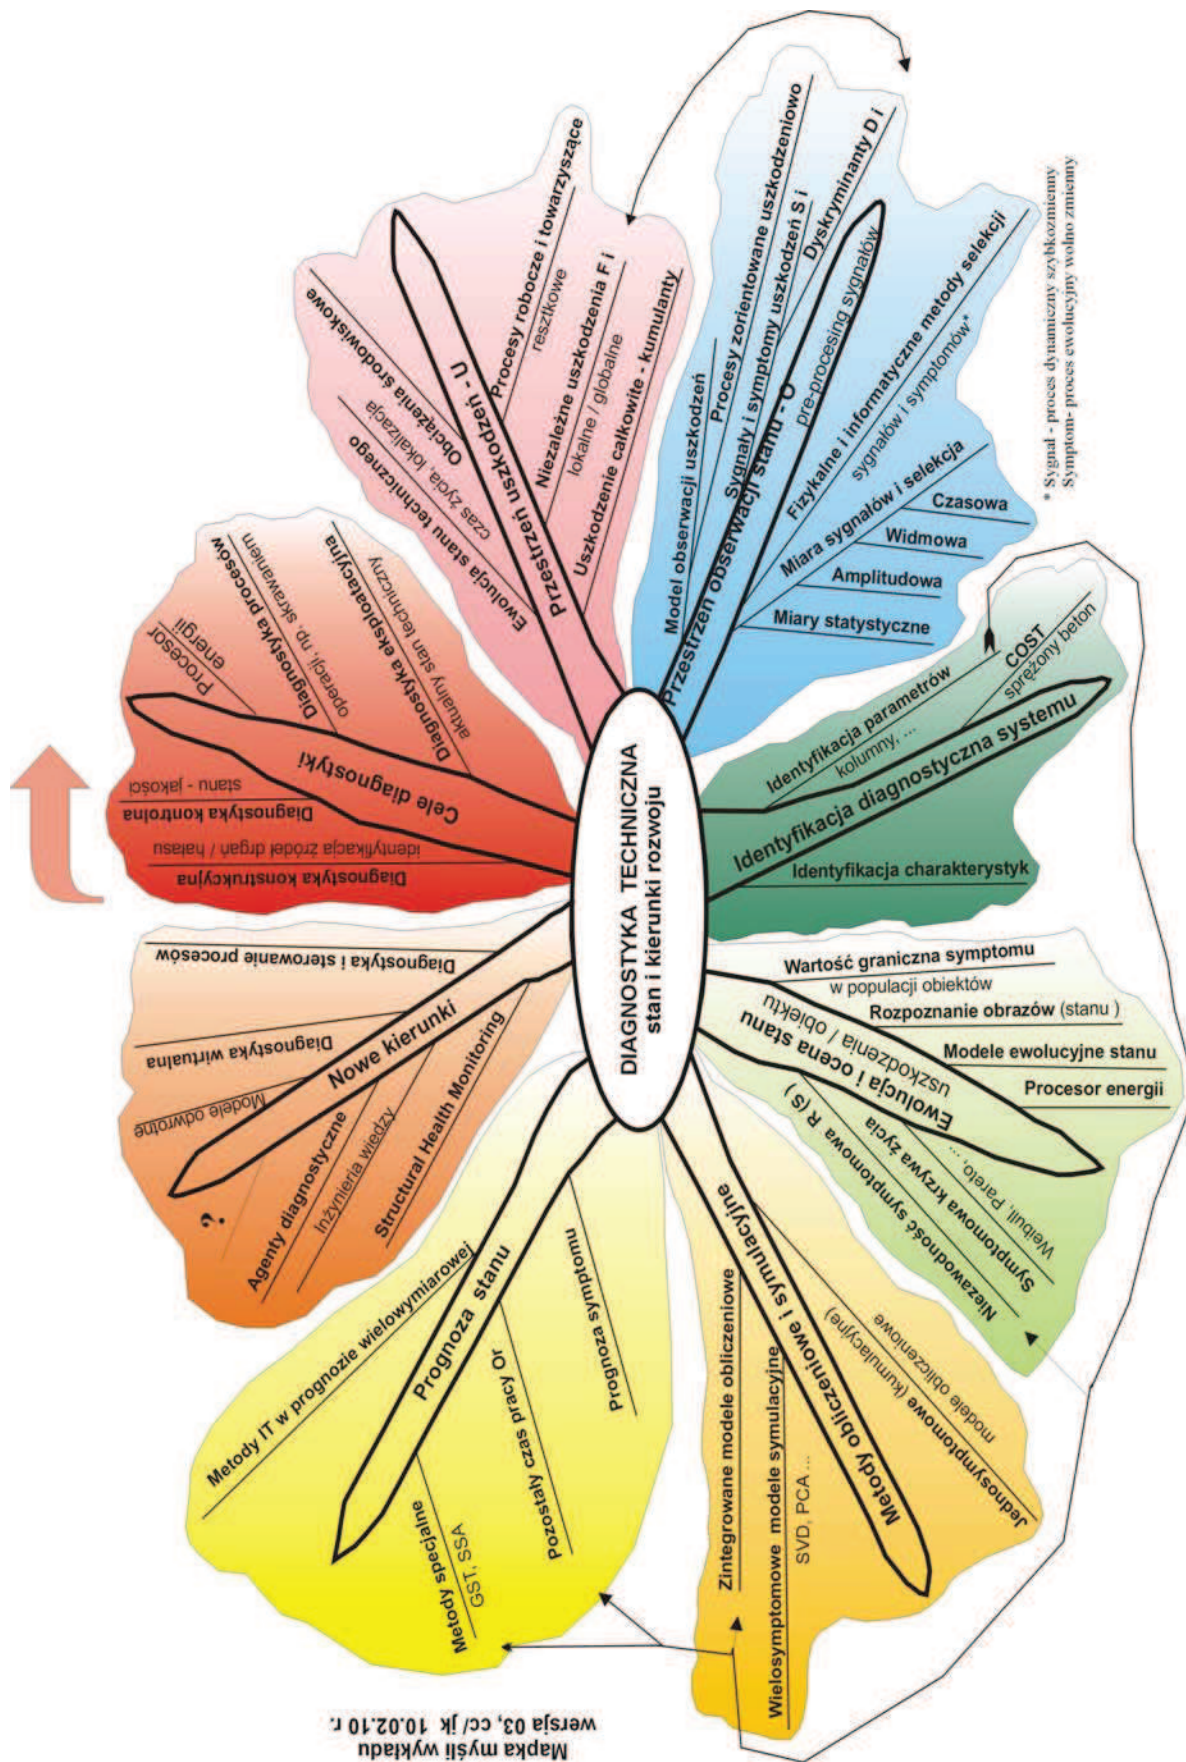
8. PODSUMOWANIE

Jak się wydaje najważniejsze elementy diagnostyki maszyn, w szczególności diagnostyki wibroakustycznej, zostały pokazane i omówione od strony idei i możliwych zastosowań. Nie wszystko

jednak zostało tu poruszone w należytej formie i treści i właściwie zintegrowane by pojąć istotę i całość dorobku diagnostyki technicznej. Ten brak jak się wydaje uzupełni mapka myślowa diagnostyki, która w sposób graficzny i kolorowy integruje całość problematyki diagnostyki, pokazując jednocześnie najważniejsze elementy pojęciowe i linie wnioskowania. Oczywiście nie wszystko, co na mapce zostało omówione w tekście, ale można to znaleźć w eksponowanej niżej literaturze przedmiotu.

Podziękowania

Praca powstała dzięki częściowemu finansowaniu z grantu R.4.09, Agent diagnostyczny w użytkowaniu maszyn i urządzeń technologicznych, Min. Nauki i Szkoln. Wyższego.



9. LITERATURA

1. Cempel C., *Diagnostyka Wibroakustyczna Maszyn*, Wyd. Politechniki Poznańskiej, Poznań, 1985,s234, również; PWN Warszawa, 1989,s234.
2. Cempel C., *Podstawy Wibroakustycznej Diagnostyki Maszyn*, WNT, Warszawa, 1982,s242.
3. Cempel C., Tomaszewski F., (red.), *Diagnostyka Maszyn, Zasady ogólne, przykłady zastosowań*, Wyd. ITE, Radom 1992, s411.
4. Żółtowski B., Cempel C., (red.), *Inżynieria Diagnostyki Maszyn*, Wyd. ITE, Radom 2004, s1110.
5. Franks L. E., *Teoria Sygnałów*, PWN, Warszawa, 1975,s401.
6. Bendat J. S., Piersol A. G., *Random Data: Analysis and Measurement Procedures*, Wiley Interscience, New York 1971,p464.
7. Bracewell R. *Przekształcenie Fouriera i jego Zastosowania*, WNT Warszawa 1968, s. 413.
8. Natke H.G., Cempel C., *Model-aided Diagnosis of Mechanical Systems*, Springer Verlag, Berlin 1997,p248.
9. Cempel C., Natke H. G., Yao J. P. T., Symptom Reliability and Hazard for Systems Condition Monitoring, *Mechanical Systems and Signal Processing*, 2000, Vol. 14, No 3, pp 495 – 505.
10. Cempel C., Energy Processors in Systems Engineering and their Evolution, *Bulletin of Polish Academy of Sciences, Technical Sciences*, Vol. 45, No 4, 1997, pp 495 – 511.
11. Cempel C., *Teoria i Inżynieria Systemów*, wyd. II, Wyd. ITE, Radom 2008, s291.
12. Cempel C., Optimization of Symptom Observation Matrix in Vibration Condition Monitoring, (referat zamawiany), XXXVI Sympozjum Diagnostyka Maszyn, Wisła Marzec, 2009. patrz także;
13. Deng J-L., Control problems of grey systems, *Systems and Control Letters*, Vol.1, No 5, March 1982, pp288-294.
14. Guo R., Repairable system modeling via grey differential equations, *Journal of Grey System*, Vol.8, No 1, 2005,pp69-91.
15. Moon I., Oh C. Y., Ride comfort indexing of commercial vehicle using a computational model and a virtual proving ground, *Journal of Automotive Engineering*, 2010, (in print)
16. Blake M. P., Mitchell W. S., *Vibration and Acoustic Measurements Handbook*, Spartan Books, New York, 1972,p350.
17. Collacot R. A., *Mechanical Fault Diagnosis*, Chapman-Hall, London 1977, p320.
18. Korbicz J., i inni (red.), *Diagnostyka Procesów - modele sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002, s828.