ZARZĄDZANIE INTELIGENTNYM TRANSPORTEM WEWNĘTRZNYM POPRAZ KOMPUTEROWE ALGORYTMY PROBABILISTYCZNE

Artykuł przedstawia model probabilistyczny w zadaniu zarządzania inteligentnym transportem wewnętrznym bazującym na ryzyku związanym z podejmowaniem decyzji. Poprzez termin niezawodności systemu transportu wewnętrznego rozumie się czas bezawaryjnego działania transportu wewnętrznego w stosunku do całości czasu, w którym dany transport powinien działać poprawnie. Artykuł przedstawia model oceny ryzyka działania transportu wewnętrznego na bazie prawdopodobieństwa z jakim system będzie bezawaryjnie funkcjonował w zadanym okresie czasu, przy pracy w określonym środowisku i dla określonego celu. Budowanie modeli probabilistycznych służących do wyznaczania ryzyka planowania produkcji opiera się na rzetelnej analizie wszystkich możliwych aspektów produkcji danego dobra gospodarczego. W modelowaniu poddaje się ocenie mocne i słabe strony przedsiębiorstwa, które chce podjąć się zadania transportowego, dokonuje się planowania samego procesu transportowego w oparciu o najważniejsze cele wynikające z procesu transportowego.

WSTĘP

Transport wewnętrzny jest ważnym aspektem przedsiębiorstwa produkcyjnego, który często stanowi problem wielu zakładów przemysłowych. Szczególną rolę odgrywa tam gdzie jego rola ma duże znaczenie przy czasie ale także kosztach poniesionych podczas produkcji.

Dzięki optymalizacji transportu wewnętrznego ale także dróg wewnętrznych możemy liczyć na znaczne obniżenie kosztów wytwarzania.

Transport w zakładach może odgrywać znaczącą rolę w mechanizmie produkcji. W zależności od rodzaju i charakteru danego przedsiębiorstwa, koszty transportu mogą znajdować się na wysokiej pozycji w hierarchii kosztów ponoszonych przez firmę. Dobrze sporządzony transport wewnętrzny to nie tylko obniżenie kosztów ale także czasu oraz jakość produkcji.

W literaturze znane są różne miękkie metody wspomagające zarządzanie systemami transportowymi, ale i prognozowaniem sprzedaży i analizy różnych problemów transportowych [4,5,6]. Artykuł pokazuje dwie metody, pierwsza do wspomagania doboru inteligentnych systemów transportowych w zależności od różnych kryteriów decyzyjnych. Drugi zaś model skupia się na wyborze najkrótszej trasy przejazdu w systemie transportu wewnętrznego między wieloma punktami docelowymi minimalizując całkowitą długość trasy.

1. PODSTAWY TEORETYCZNE TRANSPORTU

Transport wewnętrzny bądź inaczej transport wewnątrzzakładowy zaliczany jest do grupy transportu bliskiego, czyli takiego transportu, który odbywa się w obrębie jednego zakładu a granicą podziału transportu jest granica tego też zakładu.

Jest to jeden z obszarów działalności przedsiębiorstwa, co związane jest bezpośrednio z logistyką produkcji oraz odnosi się do przewozów na małe odległości, które zależne są od wielkości danego przedsiębiorstwa produkcyjnego.

Transport wewnątrzzakładowy definiowany jest również jako transport wewnętrzny, bliski bądź przemysłowy oraz odnosi się do jednego rodzaju przemieszczania.

Transport produkcyjny polega na przemieszczaniu ładunków, które związane są procesami produkcji. Obejmuje transport międzywydziałowy czyli poruszanie się np. między magazynami a także transport wydziałowy czyli np. przewozy na hali produkcyjnej.

Transport magazynowy polega na transportowaniu ładunków oraz umieszczaniu ich w magazynkach oraz składach.

Transport międzywydziałowy jest jednym z elementów transportu produkcyjnego oraz obejmuje transport między wydziałami, magazynami czy polami sadowniczymi.

Transport wydziałowy odbywa się na stanowisku roboczym.

Transport inteligentny składa się z systemu transportowego mającego zdolność samoorganizacji oraz sterowania bez udziału bezpośredniego operatora.

Rys. 1. Podział transportu

Aby transport w przedsiębiorstwie był jak najlepiej zorganizowany należy pamiętać o kilku ważnych zasadach takich jak krótka droga transportowa przy maksymalnym wykorzystaniu środków transportu, jednocześnie przy najmniejszym ich zużyciu.

Dzięki optymalizacji transportu wewnętrznego można wykorzystać w wysokim stopniu środki transportu, można lepiej zorganizować czas pracy operatorów oraz magazynierów. Optymalizacja wiąże się także ze zmniejszeniem kosztów transportu ma czym często zależy przedsiębiorca. Zmniejsza to także liczbę braków transportowych oraz upraszcza jego organizację.

Sposoby na optymalizację transportu to:

- Stworzenie jednokierunkowego przepływu strumienia materiałów, unikając nawrotów oraz skrzyżowań. Powinien płynąć prosto liniowo, po kole lub po linii S,U lub Z.
- Zmniejszyć liczbę operacji transportowych oraz usunięcie tych zbędnych
- Zmniejszenie odległości między miejscami przeładunku prowadzi do skrócenia drogi transportowej co skutkuje krótszym czasem a także mniejszymi kosztami poniesionymi na transport. Uda się wówczas zyskać oraz wykorzystać przestrzeń produkcyjną
- Zastosowanie ciągłości strumienia materiałów oraz wyeliminowanie operacji przeładunkowych. Każda przerwa przeładunkowa związana jest z opóźnieniami produkcyjnymi co w efekcie prowadzi do przestojów czy dodatkowych operacji transportowych
- Wykorzystywanie praw fizyki w systemach transportu wewnętrznego aby odciążyć pracowników np. ześlizg, spadek materiałów pod warunkiem, że nie będzie to prowadzić do uszkodzenia towaru
- Pełne wykorzystanie przestrzeni budynków poprawi wydajność pracy.
- Odpowiednia konserwacja oraz utrzymanie w dobrym stanie technicznym urządzeń transportowych oraz dróg transportowych.
- Zapewnienie bezpieczeństwa tam, gdzie operacje transportowe mogą stanowić zagrożenie dla pracowników.

2. MODEL PROBABILISTYCZNY

Doświadczeniem losowym nazywać będziemy eksperyment, zjawisko fizyczne bądź doświadczenie o którego przebiegu oraz wyniku decyduje przypadek lecz spełnione muszą być dwa warunki:

- Zbiór Ω wszystkich możliwych wyników jest co najwyżej przeliczalny
- Dla każdego wyniku możliwe jest określić a priori oraz oszacować, a posteriori, prawdopodobieństwo, z jakim doświadczenie może zakończyć się wynikiem.
- Doświadczenie losowe będzie oznaczane jako δ

Jeżeli chodzi o wynik doświadczenia losowego to musi być on co najmniej dwuelementowy. Gdy mamy do czynienia ze zbiorem, który jest co najwyżej przeliczalny, mówimy wówczas o doświadczeniu losowym ziarnistym. Wśród nich możemy wyróżnić te doświadczenia, które przebiegają etapami. Nazywać je będziemy doświadczeniami wieloetapowymi. Wśród nich natomiast wyróżnić możemy te, których liczba etapów jest losowa. Będą się one nazywać doświadczeniami losowymi o losowej liczbie etapów.

Przestrzeń probabilistyczną $(\Omega, \mathcal{P})$ nazywać będziemy modelem probabilistycznym lub inaczej modelem doświadczenia losowego δ , jeśli Ω jest zbiorem wszystkim wyników doświadczenia δ , które są możliwe. Natomiast funkcja $\mathcal{P}$ przypisywać będzie każde-

mu prawdopodobieństwu, z jakim doświadczenie δ może się zakończyć.

Optymalizacja transportu jest kluczowym elementem firm oraz istnieje wiele metod opowiadających się o stworzeniu jak najlepszego rozwiązania dla firm oraz zakładów produkcyjnych. Do tego zastosować można prawdopodobieństwo, wyliczając jaka droga oraz jaka metoda będzie najlepszym rozwiązaniem dla danego przedsiębiorstwa.

Dla dowolnego zdarzenia A oraz ciągu zdarzeń $B_1, B_2, \dots, B_n$ spełniającego następujące warunki:

$$P(B_i) > 0 \text{ dla każdego } i \in \{1, 2, \dots, n\} \quad (1)$$

$$B_i \text{ są parami rozłączne} \\ B_1 \cup B_2 \cup \dots \cup B_n = \Omega \quad (2)$$

można obliczyć jego prawdopodobieństwo całkowite za pomocą twierdzenia o prawdopodobieństwie całkowitym wyrażonego wzorem [3]

$$P(A) = P(B_1) \cdot P(A|B_1) + P(B_2) \cdot P(A|B_2) + \dots + P(B_n) \cdot P(A|B_n) \quad (3)$$

Dla każdego rozkładu prawdopodobieństwa istnieje funkcja $F: R \rightarrow [0, 1]$ zwana dystrybuantą tego rozkładu. Dla rozkładu dyskretnego funkcja ta spełnia pięć następujących warunków:

$$\lim_{x \rightarrow -\infty} F(x) = 0$$

$$\lim_{x \rightarrow +\infty} F(x) = 1$$

F jest funkcją niemalejącą

F jest funkcją lewostronnie ciągłą

F jest przedziałami funkcją stałą [2]

Dyskretny rozkład prawdopodobieństwa, z angielskiego „distribution”, oznaczamy literą d.

Z dyskretnym rozkładem prawdopodobieństwa mamy do czynienia wtedy, gdy spełnione są trzy następujące warunki:

- Dany jest podzbiór zbioru $R, X = \{x_n, n \in N_0\}$
- Dany jest ciąg liczb $p_n \in (0, 1), n \in N_0$ sumowalny do jedności
- Dane jest odwzorowanie $d: R \rightarrow \{p_n, n \in N_0\}$, takie że $d(x_n) = p_n$, dla każdego $n \in N_0$, gdzie $N_0 \leq N$ [3]

Jeśli N_0 jest skończony, to taki rozkład nazywamy skończonym rozkładem prawdopodobieństwa.

Najprostszym przykładem rozkładu dyskretnego jest rozkład dwupunktowy:

$$X = \{0, 1\}, \quad d(0) = q, \quad d(1) = p, \quad \text{dla } p \in (0, 1), q = 1 - p \quad (4)$$

Dystrybuenta rozkładu dyskretnego wyraża się wzorem:

$$F(x) = \sum_{x_n \leq x} p_n \quad (5)$$

Dystrybuenta rozkładu dwupunktowego ma postać następującą:

$$F(x) = \begin{cases} 0, & \text{gdy } x \leq 0 \\ q, & \text{gdy } x \in (0, 1] \\ 1, & \text{gdy } x > 1 \end{cases} \quad (6)$$

Do czynienia z ciągłym rozkładem prawdopodobieństwa mamy wtedy, gdy istnieje dystrybucja tego rozkładu $F: R \rightarrow [0,1]$, spełniająca następujące warunki:

$$\begin{aligned}\lim_{x \rightarrow -\infty} F(x) &= 0 \\ \lim_{x \rightarrow +\infty} F(x) &= 1 \\ F &\text{ jest funkcją niemalejącą} \\ F &\text{ jest lewostronnie ciągłą [2].}\end{aligned}$$

Przed zdefiniowaniem rozkładu normalnego należy zdefiniować funkcję gęstości rozkładu prawdopodobieństwa.

„Dla zmiennej losowej typu ciągłego pochodną jej dystrybucji będziemy nazywać funkcją gęstości prawdopodobieństwa i będziemy pisali $f_X = F'_X$.” [2]

Rozkład normalny $N(0,1)$ charakteryzuje się gęstością, której wykresem jest krzywa Gaussa, która opisana jest następującym wzorem:

$$f(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}} \quad (7)$$

Dystrybucja zmiennej losowej X posiadającej rozkład normalny $N(0,1)$ oznacza się przez Φ . Dystrybucja takiej zmiennej losowej nie jest funkcją elementarną, tzn. jej wartość należy odczytywać z tablic rozkładu normalnego.

Klasyfikator bayesowski jest jednym z podstawowych klasyfikatorów umożliwiających wyznaczenie funkcji gęstości prawdopodobieństwa *a-posteriori*, na podstawie prawdopodobieństwa *a-priori*.

Możemy założyć, że dane są prawdopodobieństwa przynależności do klas reprezentujących daną jednostkę środka transportowego bądź systemu przeladunkowego transportu wewnętrznego oznaczonych odpowiednio $P(C_1), P(C_2), \dots, P(C_n)$ przykładów z pewnej klasyfikacji. Zatem na podstawie pewnej wartości x zostaje dobrany odpowiedni środek transportowy do realizacji transportu wewnętrznego. Do tego przyjmijmy gęstości rozkładów prawdopodobieństw wystąpienia wektora obserwacji x w poszczególnych klasach przykładów $p(x|C_1), p(x|C_2), \dots, p(x|C_n)$. W ten sposób uzyskaliśmy prawdopodobieństwa zwanymi prawdopodobieństwami *a-priori*. Zapis takiego zdarzenia jest niemalże identyczny jak w przypadku prawdopodobieństwa warunkowego, aczkolwiek symbol prawdopodobieństwa zastępujemy małą literą „p”.

Korzystając z twierdzenia Bayesa możemy wyznaczyć gęstość rozkładu prawdopodobieństwa *a-posteriori* wystąpienia jakiejś klasy k względem naszego wektora obserwacji x . W zadaniu zarządzania transportem będziemy rozpatrywali taką wartość losową x , będącą parametrem decydującym o wyborze realizacji danego środka transportu wewnętrznego:

$$P(C_k|x) = \frac{p(x|C_k) \cdot P(C_k)}{p(x)} \quad (8)$$

$p(x)$ w mianowniku to gęstość rozkładu wartości wektora obserwacji i jest to suma gęstości po wszystkich klasach. Można to przedstawić za pomocą wzoru:

$$p(x) = \sum_{k=1}^n p(x|C_k). \quad (9)$$

Ważną własnością prawdopodobieństwa *a-posteriori* jest fakt, że dla wszystkich klas (środków transportowych) sumują się one do jedności w całej dziedzinie zmienności wektora obserwacji.

Ostatnim krokiem jaki nam pozostaje to przypisanie klasy (środku transportu) każdemu klasyfikowanemu wektorowi obserwacji $p(x_i)$ w taki sposób, by przypisanie to było funkcją przypisania maksymalnej wartości prawdopodobieństwa *a-posteriori*:

$$f(x) = \operatorname{argmax}_C P(C|x) \quad (10)$$

Klasyfikator bayesowski to klasyfikator optymalny pod względem minimalizacji błędów uogólnienia, pod warunkiem że wykorzystane prawdopodobieństwa i gęstości rozkładów prawdopodobieństw są prawdziwe. Potwierdza to gęstość rozkładu wartości wektora obserwacji, czyli wspomniana wcześniej suma gęstości po wszystkich klasach. Wynika to z funkcji błędów klasyfikacji:

$$\begin{aligned}P(\text{err}) &= \sum_{i=1}^n \sum_{j=1}^n P(x \in R_i, C_j) f(x) \\ &= \sum_{i=1}^n \sum_{j=1}^n P(x \in R_i | C_j) P(C_j) f(x) \\ &= \sum_{i=1}^n \sum_{j=1}^n \int_{R_i} p(x|C_j) P(C_j) f(x) dx\end{aligned} \quad (11)$$

Podobnie jak klasyczny klasyfikator bayesowski, ten także bazuje na twierdzeniu Bayesa, ale nadaje się szczególnie do rozwiązywania problemów o bardzo wielu możliwościach jakie mamy na wejściu. Ponadto metoda jest o wiele prostsza i nierzadko działa lepiej od innych metod klasyfikujących.

Klasyfikator ten nazwano „naiwnym” z powodu założenia, które wprowadza się przed rozwiązywaniem problemu, mianowicie zakłada się wzajemną niezależność zmiennych niezależnych [1]. Wyznaczanie wartości prawdopodobieństwa *a-posteriori* za pomocą tego klasyfikatora jest szybsze i łatwiejsze. Chcąc wyznaczyć wartość prawdopodobieństwa *a-posteriori* C_j ze zbioru $C = \{c_1, c_2, \dots, c_n\}$ korzystamy z twierdzenia Bayesa:

$$p(C_j|x_1, x_2, \dots, x_n) = p(x_1, x_2, \dots, x_n | C_j) \cdot f(x)p(C_j) \quad (12)$$

Jak już wiadomo, $p(x_1, x_2, \dots, x_n)$ to prawdopodobieństwo *a-posteriori* przynależności do klasy, czyli inaczej $p(x_i)$.

Następnie wykorzystując nasze założenie o wzajemnej niezależności zmiennych niezależnych możemy powyższą zależność zapisać w postaci iloczynu:

$$p(C_j|X) = p(C_j) \prod_{k=1}^n p(x_k | C_j) f(x) \quad (13)$$

Za X rozumiemy nowy przypadek, który rozpatrujemy. Przypadek ten nazywany jest szansą. Korzystając z tego samego założenia, naszą szansę także możemy zapisać w postaci iloczynu:

$$p(X|C_j) = \prod_{k=1}^n p(x_k, C_j) f(x) \quad (14)$$

Za pomocą twierdzenia Bayesa wybór środka transportu przypisujemy do klasy C_j , która ma największe prawdopodobieństwo a posteriori.

Skonstruowany model probabilistyczny pozwala na dobór najlepszego środka transportu na podstawie kryterium np. odległości x . Teraz należy wybrać najbardziej korzystną trasę transportu. Niech będą dane czasy $t_{a,b}$ oraz odległości $o_{a,b}$ ($a = 0, \dots, B$; $b = 0, 1, 2, \dots, B$) transportowe do wszystkich punktów w przedsiębiorstwie (hala produkcyjna lub magazyn). Załóżmy, że zlecenie transportowe oznaczmy przez $z_{a,b}$ wyrażone w odległości. Podana została ładowność środka transportu v wyrażona w odległości trasy. Dzięki powyższym założeniom wyznaczmy

- ilość kursów
- produkty przewożone w każdym kursie
- czas trwania kursów
- punkty docelowe transportu
- trasę każdego środka transportu

Problemem do rozwiązania jest to aby ograniczyć czas transportu do minimum, który stanowi kryterium optymalizacji problemu.

W zadaniu transportowym na początek należy zdefiniować stan procesu decyzyjnego oraz funkcję generowania kolejnych stanów. Stan procesu decyzyjnego ma postać:

$$C = [c_{b,a}] \quad b = 1, \dots, B \quad a = 1, 2. \quad (15)$$

Elementy pierwszej kolumny macierzy (11) definiujemy następująco:

$$c_{b,1} = tr, \quad (16)$$

gdzie tr - trasy (kursu) środka transportowego wyznaczonego algorytmem (10) ($tr=1,2,\dots,TR$), przy czym liczba TR tras (kursów) nie jest znana.

Elementy drugiej kolumny macierzy (11) definiujemy następująco:

$$c_{b,2} = st, \quad (17)$$

gdzie st - numer sekwencyjny (kolejny) b -tego punktu dostawy w ramach tr -tej trasy, przy czym $st=1,2,\dots,St_{tr}$, gdzie St_{tr} jest liczbą punktów dostawy na tr -tej trasie.

Przyjmując, że każdy wiersz odpowiada b -temu punktowi dostawy, $b=1\dots B$ możemy przyjąć, że w pierwszej kolumnie będziemy zapisywać numer kursu tr , w którym dostarczono produkt do b -tego punktu dostawy, a w drugiej numer kolejny st -tego punktu dostawy w tr -tej trasie. Stan początkowy G^0 jest macierzą o zerowych elementach, stan końcowy G^N nie jest znany - jest to macierz ze wszystkimi elementami dodatnimi. Stan końcowy reprezentuje dopuszczalne (w tym optymalne) rozwiązanie problemu transportu wewnętrznego. Gwarancją trajektorii, składającej się tylko z dopuszczalnych stanów, jest odpowiednio zdefiniowana procedura generowania stanów.

Stan początkowy C^0 jest macierzą o zerowych elementach. Stan końcowy C^B jest nieznany - to macierz ze wszystkimi elementami dodatnimi. Reprezentuje on [stan końcowy] dopuszczalne rozwiązanie. W algorytmie należy zapamiętywać:

- aktualne położenie środka transportu sa^{d-1} przy czym na każdej trasie środek transportu startuje z położenia 0, a na końcu wraca do 0.
- Liczbę przejechanych metrów e^{d-1} na tr -tej trasie przy czym na starcie każdej trasy $e^{d-1}=0$;
- Liczbę produktów k^{d-1} dostarczonych do punktów docelowych na tr -tej trasie, przy czym na starcie e każdej trasy $e^{d-1}=0$ a na zakończenie każdej trasy musi być spełniony warunek

$$k_{tr}^{d-1} \leq v. \quad (18)$$

Procedura generowania dopuszczalnych stanów ma postać:

$$\forall (x_{b,1}^{d-1} = 0) \Rightarrow [C^d = F(C^{d-1}, b)] p(X|C_j). \quad (19)$$

Funkcja F jest zdefiniowana następująco:
dla $i \neq b$ otrzymujemy:

$$x_{i,a}^d = x_{i,a}^{d-1}, \quad (20)$$

dla $i=b$ otrzymujemy:

$$\begin{aligned} x_{i,1}^d &= R^{d-1}, & \text{jesli} & \quad k_{tr}^{d-1} + z_b \leq v \\ x_{i,1}^d &= R^{d-1} + 1, & \text{jesli} & \quad k_{tr}^{d-1} + z_b > v \\ x_{i,2}^d &= St^{d-1} + 1, & \text{jesli} & \quad k_{tr}^{d-1} + z_b \leq v \\ x_{i,2}^d &= 1, & \text{jesli} & \quad k_{tr}^{d-1} + z_b > v \end{aligned} \quad (21)$$

gdzie:

TR^{d-1} - numer aktualnej (ostatniej) trasy,

ST^{d-1} - numer ostatniego punktu docelowego na trasie TR^{d-1} .

Numer TR^{d-1} oraz ST^{d-1} można łatwo wyznaczyć ze stanu B^{d-1} . Ponadto, w trakcie generowania stanów transportu określamy parametry:

$$\begin{aligned} sa^d &= b \\ k_{tr}^d &= k_{tr}^{d-1} + t_{sa,b} \end{aligned}$$

$$\begin{aligned} k_{tr}^d &= k_{tr}^{d-1} + z_b, & \text{jesli} & \quad k_{tr}^{d-1} + z_b \leq v \\ k_{tr}^d &= z_b, & \text{jesli} & \quad k_{tr}^{d-1} + z_b > v. \end{aligned} \quad (22)$$

PODSUMOWANIE

W artykule przedstawiono metody planowania doboru środków transportu wewnętrznego jak i planowania trasy przejazdu. W przypadku doboru odpowiedniego środka transportu zastosowano klasyfikator bayesowski. Natomiast wybór optymalnej trasy przejazdu dokonano za pomocą metody heurystycznej z prawdopodobieństwem a posteriori. Współczesne systemy transportowe coraz częściej są bezobsługowe. Opracowane metody mogą być wykorzystane w systemach softwarowych do automatyzacji przebiegu pracy, zarządzania eksploatacją i konserwacją środków transportu. Automatyczny transport podłogowy w wewnętrznym przepływie materiałów oraz w produkcji zintegrowany z zautomatyzowanym systemem prowadzenia pojazdów podłogowych coraz częściej wypiera stare systemy obsługowe. Opracowane metody mogą być zastosowane w sterowaniu opcjonalnym za pomocą systemu prowadzenia pojazdu

wzdłuż zadanego toru, gwarantując elastyczną trasę przejazdu. Inteligentne środki transportu tj. wózki bezzalogowe widłowe umożliwiają odbieranie i odkładanie palet, koszy siatkowych oraz innych pojemników.

BIBLIOGRAFIA

1. Nowak A. „Klasyfikatory: k-NN oraz naiwny Bayesa. Wykład III.”, Zakład Systemów Informatycznych, Uniwersytet Śląski, Instytut Informatyki
2. Płaskonka J., Rębowski R. „Zbiór zadań probabilistycznych”, PWSZ w Legnicy 2008
3. Rębowski R. „Podstawy metod probabilistycznych”, PWSZ w Legnicy 2015
4. K. Topolska, Publikacja: Zastosowanie inteligentnych systemów do analizy zagrożeń komunikacyjnych Czasopismo: [1231-5478] Logistyka 2014
5. K. Topolska Publikacja: Metoda oceny zarządzania zużyciem granicznym obiektów technicznych z wykorzystaniem fuzji klasyfikatorów rozmytych i heurystycznych Czasopismo: [1509-5878]Autobusy. Technika, Eksploatacja, Systemy Transportowe 2016
6. K. Topolska Publikacja: Model systemu ekspertowego rozmyto-probabilistycznego oceny zdolności obiektu technicznego w zarządzaniu linią produkcyjną Czasopismo: [1509-5878]Autobusy. Technika, Eksploatacja, Systemy Transportowe 2016

Management of intelligent internal transport through computer-based probabilistic algorithms

This article presents a proposal proprietary approach to the task of optimizing transport processes. In modern logistics, there is a very high complexity of the transport processes. The development of technology has made the systems are becoming more complex. This generates high costs and quite often only approximate the best solutions. The model shows the connection classifier Ford-Fulkerson network flow algorithm Demstera-Shafer theory based on mathematical records. This method is used to obtain the limit problems (tasks) transport. This method is based inter alia on the cost matrix, which means that usually obtained cost solution to the problem is significantly lower than using other methods. The solution acceptable - it is a temporary solution. There are many feasible solutions to a transportation problem, wherein each further has a better (lower) or at least a minimal cost from the previous.

Autorzy:

Dr inż. **Mariusz Topolski** – Wyższa Szkoła Bankowa we Wrocławiu, Instytut Logistyki, Wydział Zarządzania i Finansów

JEL: L96 DOI: 10.24136/atest.2018.211

Data zgłoszenia: 2018.05.28 Data akceptacji: 2018.06.15