

Andrzej KORNACKI
Jacek WAWRZOSEK
Andrzej BOCHNIAK
Andrzej SZYMANEK
Halina PAWLAK

Krytyczne wartości czasu reakcji kierowcy i ich wpływ na obniżenie niezawodności i bezpieczeństwa ruchu drogowego


Słowa kluczowe: *czas reakcji kierowców, niezawodność ruchu drogowego, obserwacje odstające, kryterium informacyjne Akaike, rozkład logarytmiczno-normalny*

Streszczenie Ruch drogowy należy do najbardziej niebezpiecznych rodzajów działalności człowieka. Główne przyczyny wypadków drogowych to zmęczenie kierowców, zły stan psychofizyczny kierujących oraz przecenianie swoich umiejętności podczas prowadzenia pojazdu. W niniejszej pracy skupiono uwagę na estymacji czasu reakcji kierowców, jako podstawie hipotetycznego systemu wykorzystującego radary dalekiego i krótkiego zasięgu a określającego stan psychofizyczny kierowcy w oparciu o analizę „szumu przyspieszeń” pojazdu podążającego za poprzednikiem. Wskazuje się na groźne konsekwencje faktu, że czas reakcji kierowcy jest opisywany rozkładem z ciężkimi ogonami, gdyż z tego powodu może być źródłem zagrożenia w układzie kierowca-pojazd. Skrajne wartości czasu reakcji kierowców potraktowano w pracy, jako wartości odstające. Do ich wykrycia zastosowano kryterium informacyjne Akaike [1, 2] co stanowi alternatywę w stosunku do klasycznych metod testowania hipotez. Nietypowe, bo odstające wartości interpretuje się, jako krytyczne czasy reakcji kierowców potencjalnie zagrażające niezawodności jazdy.

1. Wprowadzenie

Ruch drogowy należy do najbardziej niebezpiecznych rodzajów działalności człowieka. Składa się na to wiele czynników, w tym zawodność układu kierowca-pojazd w procesie jazdy. Według statystyk WHO, co roku na świecie, w wypadkach samochodowych ginie ponad 1,2 mln ludzi. W ciągu ostatnich 10 lat na drogach UE zginęło ok. 0,5 mln osób, a ponad 1,5 mln zostało ciężko rannych, w tym wiele osób pozostaje niepełnosprawnymi do końca życia. Roczny koszt wypadków drogowych w UE wynosi 160 miliardów € co stanowi 2% PKB UE. Ryzyko bycia ofiarą śmiertelną na drogach krajowych w Polsce jest czterokrotnie większe niż na drogach krajowych w Niemczech i Wielkiej Brytanii, a na autostradach aż sześciokrotnie większe. W Polsce w 2005 r. aż 57,3% wypadków miało miejsce na prostym odcinku drogi, a najczęściej przyczyną wypadków drogowych była nadmierna prędkość (28,8%), zaś niezachowanie bezpiecznej odległości pomiędzy pojazdami to powód 4,5% wypadków. W 2012 roku około 11% wypadków to efekt najechania na tył innego pojazdu z powodu niezachowania bezpiecznego dystansu. Przyczyną aż jednej czwartej wypadków na niemieckich autostradach jest senność kierowców. Większość z tych wypadków ma dotkliwe skutki. Głównymi czynnikami ryzyka na drogach są: człowiek, jako uczestnik ruchu, pojazd oraz droga. Aż 90-95% przyczyn wypadków związanych jest z człowiekiem i jego zachowaniem. Pojazd przyczynia się do powstawania 8-10 % wypadków drogowych, zaś droga i jej otoczenie przyczynia się do powstawania 28-35 % wypadków drogowych. Czynniki te mogą wpływać na ryzyko pojedynczo albo łączyć z sobą wpływ kilku czynników (rysunek 1)

[14, 20]. Archer [3] zaobserwował, że przy średniej prędkości 60 km/h przeciętnemu kierowcy należy przypisywać jedną sytuację ryzykowną na 120 km.



Rys. 1. Wpływ głównych czynników ryzyka na powstawanie wypadków drogowych

Zachowanie człowieka, nieznajomość własnego ciała, reakcji na stres czy poziom zmęczenia lub nadmierna wiara we własne umiejętności, jako kierowcy, wpływają na powstawanie wypadków. Inne czynniki, jak warunki atmosferyczne lub stan nawierzchni, mają zdecydowanie mniejsze znaczenie. Stąd w wielu ośrodkach prowadzone są prace nad zintegrowanymi systemami monitorowania stanu psychofizycznego kierujących pojazdami. Przegląd niektórych stosowanych obecnie i przygotowywanych systemów podnoszących bezpieczeństwo ruchu drogowego zawierają prace Wicher [34], Mercedes-Benz [27], Cieślar i Karpińska [9]. Obrazują one szeroko zakrojone prace inżynierskie m.in. koncernów SAAB, Mitsubishi, Toyota, Mercedes-Benz, Nissan, Lexus. Elektronika samochodowa jest najszybciej rozwijającym się segmentem elektroniki. I tak w 1980 r. wartość elektronicznego wyposażenia samochodów stanowiła poniżej 1% ceny pojazdu. W 1990 r. było to już blisko 7%, a w 2007 r. udział ten wzrósł do 22%. Obecne szacunki przekraczają już 40% wartości auta. Wartość elektronicznych układów sterowania pracą pojazdów rocznie rośnie obecnie już w tempie kilkunastu procent.

Teoretyczne rozważania zamieszczone w niniejszym artykule wskazują na potrzebę oraz stwarzają możliwość opracowania koncepcji kolejnego systemu, tym razem monitorującego składowe czasu reakcji psychofizjologicznej kierowcy pod kątem kalkulacji ryzyka wypadków zachodzących podczas jazdy zależnej stanowiącej zasadniczy składnik potoków ruchu drogowego.

2. Systemowa, bieżąca kontrola czasu reakcji kierowców

Indywidualne cechy fizjologiczne określają ograniczenia organizmu kierowcy. Psychologia inżynierska uwzględnia sprawdzanie następujących parametrów psychofizycznych kierowców: czas reakcji i jej stałość, ocenę prędkości pojazdów, widzenie przestrzenne, wrażliwość zmysłu kinestetycznego, wrażliwość na olśnienie i zdolność rozróżniania kształtów w mroku, szybkość i dokładność spostrzegania, szybkość i dokładność podejmowania decyzji, podzielność i koncentracja uwagi, orientacja techniczna, odporność na zmęczenie, neurotyczność [23]. Do najważniejszych cech kierowcy należą charakterystyki jakości wzroku, czas reakcji i wiek.

Czas reakcji stanowi część czasu potrzebnego do zatrzymania samochodu. Manewr zatrzymania samochodu przed pojawiającą się przeszkodą można podzielić na czas postrzegania, właściwy czas reakcji kierowcy, czas potrzebny do uruchomienia układu hamulcowego samochodu i czas właściwego hamowania. Czas postrzegania, czyli czas, jaki upływa od chwili, kiedy przeszkoda może być zauważona do chwili, kiedy rozpocznie działanie ośrodkowy układ nerwowy, jest w niektórych publikacjach włączany do przedziału czasowego zwanego czasem reakcji. Podobnie jak w tej pracy wynika to z warunków, w jakich jest przeprowadzany eksperyment. Łączny czas postrzegania i reakcji kierowcy może zmieniać się w okresie od 1 s nawet do kilku sekund, w zależności od:

- o aktualnego stanu zdrowia, samopoczucia kierowcy i cech fizycznych kierowcy (np. ból głowy, wypoczęty lub zmęczony),
- o stopnia koncentracji uwagi kierowcy (długotrwała monotonna jazda lub hałas w kabinie trwający przez dłuższy czas może wydłużyć czas reakcji o ponad 10%),
- o rytmu dobowego kierowcy (osłabienie czujności, zmęczenie, senność), pory roku, dnia i zjawisk meteorologicznych (zmiany ciśnienia atmosferycznego i temperatury otoczenia, opadów),
- o warunków ergonomicznych (np. niewłaściwe rozmieszczenie elementów układu sterowania, niedobre parametry pracy podzespołów wspomagających),
- o złożoność sytuacji drogowej (zaskoczenie wynikające z nietypowej sytuacji drogowej), ilości możliwych wariantów rozpatrywanych przez kierowcę jak i faktycznie podejmowane manewry,
- o oświetlenia drogi, charakteru drogi (ulica, droga podmiejska, autostrada),
- o stanu nietrzeźwości, działania leków psychotropowych, środków odurzających.

Jeżeli kierowca oczekuje niebezpieczeństwa to przyjmuje się, że czas reakcji wynosi 0,5-0,8 s. Jeżeli kierowca jest uważny, ale nie oczekuje niebezpieczeństwa, to 0,7-0,9 s. Gdy kierowca prowadzi pojazd nieuważnie, to 1,4-1,9 s. W komputerowej rekonstrukcji kolizji drogowej przyjmuje się często, że łączny czas postrzegania i reakcji kierowcy wynosi 1,75 s. W nocy czas ten jest dłuższy i wynosi 2,5 s [5].

Czasy reakcji szacowane na podstawie symulacyjnych testów laboratoryjnych należy przyjmować bardzo ostrożnie. Większość takich testów polega na pomiarze czasu reakcji kierowcy na prosty sygnał, tj. taki jak pomiar czasu, jaki upływa od pojawienia się czerwonego światła do chwili naciśnięcia na pedał hamulca. Testy te nie odzwierciedlają rzeczywistych warunków, w jakich znajduje się kierowca w ruchu drogowym i pomierzone czasy reakcji są znacznie krótsze [35].

Składniki obecnie instalowanego dodatkowego wyposażenia pojazdu tj. połączenie kamery stereoskopowej i czujników radarowych dalekiego i krótkiego zasięgu po odpowiednim przeprogramowaniu pozwalają na bezpośredni pomiar czasu reakcji kierowcy pojazdu podążającego za innym pojazdem. Wielokrotny pomiar czasu, jaki mija od chwili, gdy pojazd poprzedzający hamuje do chwili reakcji kierowcy pojazdu podążającego, może być parametrem wykorzystywanym w rozmaity sposób. Może np. posłużyć do ostrzeżenia kierowcy o jego złym stanie psychofizycznym, o potrzebie zmiany stylu jazdy lub parametrów podzespołów, może też prowadzić do ograniczenia prędkości pojazdu, czasowego wyłączenia go z ruchu, zasygnalizowania problemu innym użytkownikom a nawet powiadomienia policji o zagrożeniu.

3. Krytyczny czas reakcji kierowców

Celem porównania różnych sytuacji ruchowych Jones i Potts [21] zaproponowali probabilistyczny opis ruchu drogowego, gdzie ważną rolę przyznano parametrowi σ_a – dyspersji przyspieszenia, zwanemu potocznie „szumem przyspieszeń” pojazdu podążającego za poprzednikiem (tak zwanej jazdy zależnej). Badania modelowe wykorzystywały ten wskaźnik jakości ruchu drogowego. Szum przyspieszenia ma zarówno składnik podłużny jak i poprzeczny. Ten ostatni szczególnie objawia się na krętej drodze, ale nie jest jeszcze należycie zbadany [22]. Rozważa się zazwyczaj tylko podłużny składnik wyrażany przez parametr σ_a – dyspersję przyspieszenia [4, 35]. Wskaźnik σ_a był weryfikowany w badaniach symulacyjnych, a wyniki potwierdzały jego korelację ze statystycznymi wskaźnikami bezpieczeństwa. Nie przeprowadzono do tej pory skutecznych badań na obiektach rzeczywistych. Tragiczna śmierć polskiego prekursora analizy ruchu rzeczywistego dr inż. Mieczysława Kaczora przerwała już rozpoczęte badania [23].

Przy tym dyspersja przyspieszenia jest konsekwencją czasu reakcji kierowcy na obserwowane bodźce i jej intensywność, które są powiązane z predyspozycjami psychofizycznymi kierowcy objawiającymi się stylem jazdy. Dyspersja przyspieszenia jest również funkcją osiągow pojazdów uczestniczących w ruchu drogowym.

„Szum przyspieszenia” (niekiedy określany jako „szum przyspieszeń”), to średnie kwadratowe odchylenie rozkładu przyspieszeń pojazdów uczestniczących w ruchu [13]. Wskaźnik ten określa niemożność utrzymania stałej prędkości jazdy. Jeżeli do określenia poziomu „szumu przyspieszenia” wykorzystamy metodę pomiaru tzw. „pływającego” pojazdu, to „szum przyspieszenia” potoku ruchu z niewielkim błędem wynikającym z ograniczonego czasu pomiarów T , można określić mierząc zmiany przyspieszenia pojazdu testowego. Wówczas:

$$\sigma_a = \lim_{T \rightarrow \infty} \sqrt{\frac{1}{T} \int_0^T [a(t) - \bar{a}]^2 dt},$$

gdzie $a(t)$, \bar{a} – są odpowiednio: realizacjami procesu stochastycznego $X(t)$ (losowych w czasie zmian przyspieszenia pojazdu testowego) oraz średnim przyspieszeniem pojazdu testowego na odcinku pomiarowym $\langle 0; T \rangle$.

Badanie krytycznego czasu reakcji kierowców powinno pozwolić na pokazanie zależności pomiędzy potencjalnie niebezpiecznymi sytuacjami drogowo-ruchowymi a następującymi kategoriami czasu reakcji kierowcy: typowy i nietypowy, dozwolony i niedozwolony, bezpieczny i zagrażający bezpieczeństwu. Przypisanie dowolnej z tych kategorii może dotyczyć pojedynczego pomiaru jak i grupy pomiarów. W ostatnim przypadku odnosić będziemy to do bieżącej charakterystyki cech fizjologicznych kierowcy np. przemęczenia, nietrzeźwości. Znając wzorcową, typową indywidualną charakterystykę czasu reakcji kierowcy łatwo porównać ją z charakterystyką bieżącego strumienia danych a następnie zapobiec potencjalnemu zagrożeniu. Podobnie, jak w systemach monitorujących zmęczenie kierowcy poprzez analizę ruchów i fiksacji gałki ocznej: tam także następuje porównanie cyfrowego wzorca „oka wypoczętego” z rzeczywistymi obserwacjami oka kierowcy za pomocą kamer w trakcie całej podróży.

Każda z tych charakterystyk oparta może być 1) na pomiarze procentu wartości skrajnych przekraczających pewną barierę lub 2) na przefiltrowaniu strumienia danych tak, by wyróżniona grupa wielokrotnych pomiarów odpowiadała rzeczywistemu rozkładowi

prawdopodobieństwa bieżącego czasu reakcji. Łącząc obie metody można określić 3) parametr częstotliwości nietypowych reakcji kierowcy.

System zarządzania strumieniem danych napływających z poszczególnych czujników wymaga skomplikowanego filtrowania i aktywacji alarmu w odpowiedzi na nietypowe obserwacje [18]. W niniejszej pracy skrajne wartości czasu reakcji kierowcy są traktowane, jako wartości tzw. „odstających pomiarów”. Przy klasycznej analizie statystycznej wyników eksperymentów ważne jest stwierdzenie czy odstające obserwacje pochodzą z innej populacji niż reszta wyników. Wtedy w dalszej analizie zwykle się odrzucać obserwacje nietypowe. Jest też możliwe, chociaż mało prawdopodobne, pojawienie się „dziwnych” obserwacji przy rozkładzie takim jak dla pozostałych wyników. Wtedy należałoby takie obserwacje zachować do dalszej analizy statystycznej zwiększając tym samym jej efektywność.

Do wykrywania obserwacji odstających stosuje się najczęściej metody testowania hipotez [6, 8, 15, 19, 30, 32]. W metodzie testowania hipotez konkluzje są jednak zależne od przyjętego poziomu istotności i mogą być różne dla różnych jego wartości. Ponadto może pojawiać się efekt „maskowania” odstających obserwacji. Grubbs [19] dla danych dotyczących wytrzymałości materiałów plastycznych opisuje sytuację, gdy testy nie wykrywają jednej najmniejszej obserwacji natomiast dwie najmniejsze obserwacje są już identyfikowane, jako odstające (pewna sprzeczność).

W niniejszej pracy sugeruje się zastosowanie do wykrywania odstających obserwacji kryterium informacyjnego Akaike. Kryterium to wywodzące się z teorii informacji pozwala na wybór tego spośród modeli opisujących dane eksperymentalne, który maksymalizuje entropię [1, 2]. Wartość tego kryterium jest równa wg Sakamoto [31]:

$$AIC = -2 \ln(\max \text{ wiarogodności}) + 2K, \quad (1)$$

gdzie $\max \text{ wiarogodności}$ oznacza wiarogodność obliczoną dla estymatorów parametrów uzyskanych metodą największej wiarogodności, zaś K liczbę tych parametrów. Wybieramy ten model, dla którego wartość AIC jest najmniejsza. Taki sposób postępowania jest niezależny od poziomu istotności, ilości odstających obserwacji oraz tego czy „podejrzane” obserwacje należą do grupy obserwacji najmniejszych czy największych.

4. Rozkład logarytmiczno-normalny

Okazuje się, iż do opisu specyficznych losowych wielkości dodatnich, tu rozkładu czasu reakcji kierowcy dobrze nadaje się rozkład logarytmiczno-normalny.

Definicja: Zmienna losowa X ma rozkład logarytmiczno-normalny o parametrach μ, σ^2 oznaczany $LN(\mu, \sigma^2)$, gdy jej logarytm ma rozkład normalny, czyli $Y = \ln X \sim N(\mu, \sigma^2)$. Zatem mamy:

$$X \sim LN(\mu, \sigma^2) \Leftrightarrow Y = \ln X \sim N(\mu, \sigma^2). \quad (2)$$

Większość z modeli probabilistycznych nie uwzględniała faktu powszechnego występowania tak zwanych grubych ogonów i asymetrii w rozkładach zmiennych losowych opisujących wartości ekstremalne [17 §3.2.1; 10; 16 §2]. Ocenia się, że metody zarządzania ryzykiem oparte na teorii wartości ekstremalnych nie mają tych wad a pozwalają skutecznie modelować rzadkie, ale groźne zdarzenia. Do budowy modeli z wartościami ekstremalnymi dla danych rzeczywistych często proponuje się rozkład logarytmiczno-normalny [7 §3.3, §4.5.2].

Zastosowania inżynierskie tego rozkładu wynikają też z faktu, że przy opisie błędów pomiarowych często musimy założyć, że różnica wyniku pomiaru od rzeczywistej wartości parametru jest wielkością dodatnią. Przykładami są tutaj zjawiska, w których nominalne wartości parametrów są równe zeru, np. poziomy odniesienia dla osadów zanieczyszczeń w gruncie, wodzie lub powietrzu; lub odległość środków (osi) elementów, które powinny być koncentryczne (współosiowe). Kotulski i Szczepiński [25] podają przykłady dobrego opisanie za pomocą rozkładu logarytmiczno-normalnego wyników stężenia wanadu w osadach oraz kadmu w glebie. W pracy [28] pokazano, że rozkład logarytmiczno-normalny może być odpowiedni do opisu testu fragmentacji przeprowadzanego dla kompozytów zbrojonych włóknami. Przykład wykorzystania tego rozkładu do opisu parametru w modelu wzrostu szczeliny zmęczeniowej można znaleźć u Dolińskiego [12]. Zastosowania rozkładu logarytmiczno-normalnego związane z problemami teorii niezawodności podane są w pracach [23 10, 28, 33], a w teorii wartości ekstremalnych do prognozowania ostrzegawczego w hydrologii w pracy [26]. Podstawowe charakterystyki rozkładu LN podaje tablica 1 [29].

Tablica 1 Podstawowe charakterystyki rozkładu logarytmiczno-normalnego

Parametry	$0 \leq \mu < \infty, \quad \sigma > 0$
Nośnik	$x \in (0, \infty)$
Wartość oczekiwana	$e^{\mu + \frac{\sigma^2}{2}}$
Wariancja	$(e^{\sigma^2} - 1)e^{2\mu + \sigma^2}$

Wiadomo, że estymatory największej wiarygodności parametrów rozkładu logarytmiczno-normalnego są równe [24]:

$$\hat{\mu} = \frac{\sum_{i=1}^n \ln x_i}{n}, \quad \hat{\sigma}^2 = \frac{\sum_{i=1}^n (\ln x_i - \hat{\mu})^2}{n}. \quad (3)$$

Rozważmy próbę n obserwacji, które po uporządkowaniu według rosnących wartości tworzą ciąg: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$. Zatem $x_{(i)}$ oznacza wartość i -tej statystyki pozycyjnej $X_{i:n}$ z n -elementowej próby prostej x . W dalszej części artykułu przyjęto następujące oznaczenia:

$\Psi(x, \mu, \sigma^2)$ oznacza funkcję gęstości prawdopodobieństwa rozkładu $LN(\mu, \sigma^2)$,

$\Phi(x, \mu, \sigma^2)$ oznacza dystrybuantę rozkładu $LN(\mu, \sigma^2)$,

$f_{i:n}(x, \mu, \sigma^2)$ oznacza funkcję gęstości prawdopodobieństwa i -tej statystyki pozycyjnej $X_{i:n}$.

Zatem mamy [11]:

$$\Psi(x, \mu, \sigma^2) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left[-\frac{(\ln x - \mu)^2}{2\sigma^2}\right], \quad x > 0, \quad (4)$$

$$\Phi(x, \mu, \sigma^2) = \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left[\frac{\ln x - \mu}{\sigma\sqrt{2}}\right], \quad x > 0, \quad (5)$$

$$f_{i:n}(x, \mu, \sigma^2) = [B(i, n-i+1)]^{-1} [\Phi(x, \mu, \sigma^2)]^{-1} [1 - \Phi(x, \mu, \sigma^2)]^{n-i} \Psi(x, \mu, \sigma^2), \quad (6)$$

gdzie erf jest funkcją specjalną (nieelementarną) zwaną funkcją błędu Gaussa, $B(p, q)$ oznacza funkcję specjalną beta:

$$B(p, q) = \int_0^1 t^{p-1} (1-t)^{q-1} dt, \quad p > 0, \quad q > 0. \quad (7)$$

Wiadomo, że:

$$B(p, q) = \frac{\Gamma(p)\Gamma(q)}{\Gamma(p+q)} = \frac{(p-1)!(q-1)!}{(p+q-1)!} \quad (8)$$

dla naturalnych p i q , zaś $\Gamma(x)$ oznacza funkcję specjalną gamma Eulera.

Oznaczając $EX = \mu'$, $VAR(X) = (\sigma')^2$ widać z tablicy 1, że zarówno μ' jak i $(\sigma')^2$ zależą od parametrów μ , σ^2 i na odwrót. Zatem wszystkie funkcje Φ , Ψ jak i $f_{i:n}$ są zależne od μ' i $(\sigma')^2$.

5. Model odstających obserwacji

Rozważamy następującą sytuację: dana jest uporządkowana n elementowa próba

$$\underbrace{X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n_1)}}_{n_1 \text{ najmniejszych obserwacji}} \leq \overbrace{X_{(n_1+1)} \leq \dots \leq X_{(n-n_2)}}^{\text{główna część próby}} \leq \underbrace{X_{(n-n_2+1)} \leq \dots \leq X_{(n)}}_{n_2 \text{ największych}} \quad (9)$$

z rozkładu logarytmiczno-normalnego. 'Główna część' próby pochodzi z populacji o średniej μ' , zaś odstające mogą stanowić grupę obserwacji najmniejszych lub grupę obserwacji największych pochodzą one z populacji o różnych średnich μ'_1 i μ'_2 . Wykrywanie obserwacji odstających na ogół odbywa się przy pomocy procedury testowania hipotez na pewnym poziomie istotności. Wtedy odpowiednie hipotezy mają postać:

H_0 - brak obserwacji odstających, czyli $\mu'_1 = \mu' = \mu'_2$,

H_{1a} - istnieją najmniejsze obserwacje odstające, czyli $\mu'_1 < \mu'$,

H_{1b} - istnieją największe obserwacje odstające, czyli $\mu' < \mu'_2$,

H_{1c} - istnieją najmniejsze i największe obserwacje odstające, czyli $\mu'_1 < \mu' < \mu'_2$.

Tu obserwacje odstające wyznacza się wykorzystując kryterium informacyjnego Akaike. Stąd kładąc wartości parametrów odpowiednio: $\mu_1 < \mu < \mu_2$ oraz takie samo σ dla wszystkich grup obserwacji dostajemy:

$$\mu'_1 < \mu' < \mu'_2 \quad \text{i} \quad \sigma'_1 < \sigma' < \sigma'_2. \quad (10)$$

Zatem model z odstającymi obserwacjami można opisać następująco:

$$h(x_{(i)}) = \begin{cases} \Psi(x_{(i)}, \mu_1, \sigma^2) & \text{dla } i = 1, \dots, n_1 \\ f_{i-n_1:n-n_1-n_2}(x_{(i)}, \mu, \sigma^2) & \text{dla } i = n_1 + 1, \dots, n - n_2 \\ \Psi(x_{(i)}, \mu_2, \sigma^2) & \text{dla } i = n - n_2 + 1, \dots, n \end{cases} . \quad (11)$$

6. Kryterium informacyjne Akaike

Aby wyznaczyć wartość kryterium informacyjnego Akaike (1) dla modelu (11) znajdujemy jego funkcję wiarygodności:

$$L(n_1, n_2, \mu, \mu_1, \mu_2, \sigma^2 | \mathbf{x}) = \prod_i^{n_1} \Psi(x_{(i)}, \mu_1, \sigma^2) \prod_{i=n_1+1}^{n-n_2} f_{i-n_1:n-n_1-n_2}(x_{(i)}, \mu, \sigma^2) \prod_{i=n-n_2+1}^n \Psi(x_{(i)}, \mu_2, \sigma^2)$$

Zatem wobec (4), (5) i (6) logarytm funkcji wiarygodności jest równy:

$$\left(\begin{aligned} \ln L(n_1, n_2, \mu, \mu_1, \mu_2, \sigma^2 | \mathbf{x}) &= l(n_1, n_2, \mu, \mu_1, \mu_2, \sigma^2 | \mathbf{x}) = \ln \prod_{i=1}^{n_1} \frac{1}{x_{(i)} \sigma \sqrt{2\pi}} \exp \left[-\frac{(\ln x_{(i)} - \mu_1)^2}{2\sigma^2} \right] + \\ &+ \ln \left[\prod_{i=n_1+1}^{n-n_2} [B(i-n_1, n-n_1-n_2-i+n_1+1)]^{-1} [\Phi(x_{(i)}, \mu, \sigma^2)]^{i-n_1-1} [1-\Phi(x_{(i)}, \mu, \sigma^2)]^{n-n_1-n_2-i+n_1} \times \right. \\ &\left. \times \frac{1}{x_{(i)} \sigma \sqrt{2\pi}} \exp \left[-\frac{(\ln x_{(i)} - \mu)^2}{2\sigma^2} \right] \right] + \ln \prod_{i=n-n_2+1}^n \frac{1}{x_{(i)} \sigma \sqrt{2\pi}} \exp \left[-\frac{(\ln x_{(i)} - \mu_2)^2}{2\sigma^2} \right], \end{aligned} \right) \quad (12)$$

czyli

$$\left\{ \begin{aligned} l(n_1, n_2, \mu, \mu_1, \mu_2, \sigma^2 | \mathbf{x}) &= -\frac{1}{2} \left\{ n \ln(2\pi) + n \ln(\sigma^2) + \frac{1}{\sigma^2} \sum_{i=1}^n (\ln x_{(i)} - \mu^i)^2 \right\} \\ &- \sum_{i=1}^n \ln x_{(i)} - \sum_{i=n_1+1}^{n-n_2} \left\{ \ln B(j, k-j+1) - (j-1) \ln \Phi(x_{(i)}) - (k-j) \ln [1-\Phi(x_{(i)})] \right\} \end{aligned} \right\}, \quad (13)$$

gdzie $j = i - n_1$, $k = n - n_1 - n_2$ oraz:

$$\mu^i = \begin{cases} \mu_1 & \text{dla } 1 \leq i \leq n_1 \\ \mu & \text{dla } n_1 < i \leq n - n_2 \\ \mu_2 & \text{dla } n - n_2 < i \leq n \end{cases} . \quad (14)$$

Ostatecznie, więc dla obserwowanej próby \mathbf{x} zależna od n_1 i od n_2 wartość funkcji kryterium informacyjnego Akaike $AIC(n_1, n_2)$ jest równa:

$$AIC(n_1, n_2) = \begin{cases} -2l(n_1, n_2; \hat{\mu}, \hat{\sigma}^2 | \mathbf{x}) + 2 \cdot 2 & \text{dla } n_1 = 0, n_2 = 0 \\ -2l(n_1, n_2; \hat{\mu}, \hat{\mu}_1, \hat{\sigma}^2 | \mathbf{x}) + 2 \cdot 3 & \text{dla } n_1 \neq 0, n_2 = 0 \\ -2l(n_1, n_2; \hat{\mu}, \hat{\mu}_2, \hat{\sigma}^2 | \mathbf{x}) + 2 \cdot 3 & \text{dla } n_1 = 0, n_2 \neq 0 \\ -2l(n_1, n_2; \hat{\mu}, \hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}^2 | \mathbf{x}) + 2 \cdot 4 & \text{dla } n_1 \neq 0, n_2 \neq 0 \end{cases}, \quad (15)$$


gdzie $\hat{\mu}$, $\hat{\mu}_1$, $\hat{\mu}_2$ i $\hat{\sigma}^2$ oznaczają estymatory parametrów modelu uzyskane metodą największej wiarygodności.

7. Badania eksperymentalne

Badania eksperymentalne przeprowadzono w Instytucie Systemów Transportowych i Elektrotechniki Uniwersytetu Technologiczno-Humanistycznego w Radomiu. Czasy reakcji kierowcy rejestrowane były przy ustalonym natężeniu rzeczywistego ruchu drogowego oraz przy ustalonych warunkach biometeorologicznych za pomocą urządzenia umożliwiającego pomiar zarówno w warunkach stacjonarnych jak i dynamicznych. Urządzenie odbierało sygnał drogą radiową z pojazdu poprzedzającego, w którym zainstalowany był nadajnik uruchomiony przez naciśnięcie pedału hamulca. Napięcie zasilające światła stopu włączało sygnał w nadajniku impulsów pomiarowych. W podążającym za nim pojeździe z badanym kierowcą zainstalowany był odbiornik impulsów oraz elektroniczny miernik czasu mierzący liczbę impulsów pomiarowych i przetwarzający go na czas z dokładnością do $10^{-3}s$. Naciśnięcie pedału hamulca przez badanego kierowcę powodowało zatrzymanie miernika czasu i zapis czasu reakcji kierowcy z dokładnością wspomnianą wyżej. Równocześnie przez przednią szybę filmowana była sytuacja na drodze [23].

8. Wyniki

Przykładowy uzyskany w badaniach reprezentatywny strumień wyników pomiarów czasu reakcji jednego z kierowców ilustruje histogram (rysunek 2). Okazuje się, że czas reakcji kierowcy ma rozkład logarytmiczno-normalny. Potwierdzeniem tego faktu jest kształt histogramu, jak i wyniki testów statystycznych (tablica 2).



Rys 2. Histogram rozkładu zaobserwowanego strumienia czasu reakcji jednego z kierowców i dopasowany rozkład logarytmiczno-normalny.

Tablica 2. Testy dopasowania obserwacji do rozkładu logarytmiczno-normalnego

Test	Dane z obserwacjami odstającymi		Dane po odrzuceniu obserwacji odstających	
	Statystyka	Wartość p	Statystyka	Wartość p
Kołmogorow-Smirnow	$D = 0,1244$	$> 0,150$	$D = 0,1003$	$> 0,150$
Cramer-von Mises	$W^2 = 0,1169$	0,067	$W^2 = 0,0412$	0,5
Anderson-Darling	$A^2 = 0,6769$	0,075	$A^2 = 0,3109$	0,5

Wartości wszystkich testów: Kołmogorowa Smirnowa, Cramera-von Misesa oraz Andersona-Darlinga z trzeciej kolumny tablicy 2 jednoznacznie wskazują, iż nie ma podstaw do odrzucenia hipotezy o logarytmiczno-normalnym rozkładzie czasu reakcji kierowcy. Obliczenia wartości testów i rysunki wykonano w programie SAS wersja 9.3.


Korzystając z teorii rozwiniętej w poprzednich rozdziałach znaleziono wartości kryterium informacyjnego Akaike *AIC* dla różnych konfiguracji odstających obserwacji (różnej liczby najmniejszych i największych odstających obserwacji). Uzyskane rezultaty prezentuje tablica 3.

Tablica 3. Wartości kryterium informacyjnego *AIC* dla różnych konfiguracji odstających obserwacji

		Liczba największych odstających wartości										
		0	1	2	3	4	5	6	7	8	9	10
Liczba najmniejszych odstających wartości	0	-30,10	-41,77	-42,85	-44,95	-46,84	-47,75	-45,28	-40,82	-36,02	-30,40	-24,93
	1	-23,35	-37,29	-39,57	-43,38	-47,37	-50,75	-50,22	-46,33	-42,26	-37,43	-31,70
	2	-16,25	-31,55	-35,10	-40,71	-46,88	-52,49	-53,43*	-50,10	-46,58	-41,80	-35,23
	3	-12,11	-27,34	-30,78	-36,39	-42,69	-48,51	-49,48	-45,86	-42,01	-36,69	-29,35
	4	-7,68	-22,82	-26,19	-31,86	-38,34	-44,44	-45,45	-41,52	-37,29	-31,24	-22,91
	5	-3,64	-18,57	-21,80	-27,43	-33,96	-40,17	-41,02	-36,66	-31,86	-24,73	-15,16
	6	-0,36	-14,98	-17,97	-23,44	-29,87	-35,98	-36,46	-31,55	-26,01	-17,49	-6,53
	7	3,38	-10,84	-13,59	-18,87	-25,17	-31,04	-30,87	-25,19	-18,53	-7,72	5,40
	8	4,07	-9,83	-12,22	-17,11	-23,00	-28,42	-27,62	-21,31	-13,80	-1,53	12,72
	9	4,65	-9,00	-11,06	-15,59	-21,11	-26,13	-24,74	-17,82	-9,49	4,24	19,57
	10	5,48	-7,98	-9,71	-13,92	-19,09	-23,74	-21,74	-14,17	-4,95	10,45	27,00

* optymalna konfiguracja próby

Jak widać z tablicy 3, oznaczona gwiazdką najmniejsza wartość kryterium informacyjnego Akaike *AIC* wskazuje, iż w badanym strumieniu odstającymi czasami reakcji są czasy zestawu obejmującego dwie najmniejsze i sześć największych wartości. Są to wyróżnione na rysunku 3 czasy znacznie odbiegające od prostej, która przy zastosowaniu skali logarytmicznej odpowiada linii regresji $y = 8,056 \cdot \exp(0,0306 \cdot i)$ dla $n_1 < i \leq n - n_2$ charakteryzującej stan psychofizyczny analizowanego kierowcy typowy dla badanego okresu. Po odrzuceniu skrajnych obserwacji wartości 2 z 3 testów dopasowania strumienia danych do rozkładu logarytmiczno-normalnego w tablicy 2 wypadają na wysokości mediany. Tym samym w najwyższym stopniu jednoznacznie wskazują, iż nie ma podstaw do odrzucenia hipotezy o logarytmiczno-normalnym rozkładzie typowego czasu reakcji kierowcy. Ponadto potwierdzają słuszność identyfikowania tych obserwacji odstających, jako nietypowych dla tego kierowcy. Słuszność obranej metodyki potwierdzona jest pełną zgodnością wszystkich zastosowanych procedur statystycznych.



Rys 3. Dwie zaobserwowane grupy czasów reakcji kierowcy są krytyczne dla poziomu niezawodności układu kierowca-pojazd w procesie jazdy.

9. Wnioski

Funkcję prawdopodobieństwa $R(t) = 1 - F(t) = P(T \geq t)$ klasycznie zwaną funkcją niezawodności (*reliability function*) lub funkcją przeżycia, z uwagi na pejoratywny charakter długiego czasu T reakcji kierowcy tu należy nazwać „funkcją ryzyka”. Ponieważ dla $t = 0$ wartość $R(0) = 1$ oraz $\lim_{t \rightarrow \infty} R(t) = 0$, zatem „funkcja ryzyka” jest nierosnącą funkcją czasu t a wyraża ona prawdopodobieństwo prawego „ogona” rozkładu. Tzn. „funkcja ryzyka” odnosi się do opisu prawdopodobieństwa najbardziej niekorzystnych dla bezpieczeństwa ruchu drogowego wartości ekstremalnych. Stąd należy zwracać uwagę na tempo zbieżności prawego ogona do 0. W układach opisanych rozkładami normalnymi pojawianie się zdarzeń ekstremalnych (z ogonów) jest na tyle małe, że w praktyce takich zdarzeń wcale się nie obserwuje. Wyraża to prawo trzech sigm. Zaś pojedynczy długi czas reakcji kierowcy stanowi istotne zagrożenie dla bezpieczeństwa ruchu drogowego. Stąd stwierdzenie, że czas reakcji kierowcy w rzeczywistym ruchu drogowym ma rozkład logarytmiczno-normalny oznacza, że rozkład czasu reakcji kierowcy ma ciężki prawy ogon tj., że czasy reakcji mogą osiągać wartości relatywnie bardzo duże z istotnymi prawdopodobieństwami. Stąd już identyfikacja czasu reakcji kierowcy w rzeczywistym ruchu drogowym, jako zmiennej posiadającej grubo prawy ogon rozkładu logarytmiczno-normalnego, wskazuje go, jako na główne źródło zagrożeń w ruchu drogowym. Zaś zauważenie na reprezentatywnym rysunku 3, że sześć największych odstających obserwacji z prawego ogona znacznie przewyższa wartości już i tak ciężkiego prawego ogona dodatkowo potęguje groźbę sytuacji niebezpiecznych. Ponadto na rysunku 3 odbieganie w dół dwóch najkrótszych czasów reakcji od typowego rozkładu czasów wskazuje na nerwowe reakcje prowadzącego pojazd. Te wyniki mogą wskazywać także na utratę (pogorszenie) płynności jazdy, a to jest skorelowane ze wzrostem zagrożenie, a w konsekwencji ryzyka wypadku drogowego. Stąd ta dodatkowa identyfikacja obu grup krytycznych czasów reakcji kierowcy przy ciężkim prawym ogonie jego rozkładu łącznie wskazuje na istniejące po stronie kierowcy trzy potencjalne zagrożenia dla obniżenia niezawodności układu kierowca-pojazd, w efekcie pogorszenia stanu bezpieczeństwa ruchu drogowego. Zatem niezbędne jest

poszukiwanie systemów wsparcia kierowców, które są nakierowane na eliminację tych zagrożeń.

Literatura

1. Akaike H. Information theory and an extension of the maximum likelihood principle. 2nd International Symposium on Information Theory. Eds. B.N. Petrv and F. Csaki. Budapest: Akademia Kiado, 1973; 267-281.
2. Akaike H. On entropy maximization principle. Proc Symposium on Applications of Statistics. Ed. P.R. Krishnaiah. Amsterdam: North Holland, 1977; 27-47.
3. Archer J. Methods for the Assessment and Prediction of Traffic Safety at Urban Intersections and their Application in Micro-simulation Modelling Academic Thesis. Division of Transport and Logistics, Stockholm: Royal Institute of Technology, Kungliga Tekniska Högskolan (KTH) SE-100 44, 2004.
4. Ashton W D. The theory of road traffic flow. London: Methuen & Co. Ltd. 1966.
5. Badger J E. Human factors affecting perception. Law and Order Magazine, 1996.
6. Barnett V, Lewis T. Outliers in Statistical Data. John Wiley & Sons, 1994.
7. Benjamin J R, Cornell C A. Probability, Statistics, and Decision for Civil Engineers. New York: McGraw-Hill Book Company, 2014.
8. Breuning M, Kriegel H P, Sander J. LOF: Identifying Density-Based Local Outliers. In Proceedings of the ACM SIGMOND Conference, 2000; 93-104.
9. Cieślak K, Karpińska O. Przyszłość za kierownicą – czy samochód będzie myśleć za nas? Translogistics 2014; 95-108.
10. Cooke R M, Nieboer D. Heavy-tailed distributions: Data, diagnostics, and new developments. Resources for the Future Discussion Paper, Washington, 2011; (11-19), [online: <http://www.rff.org/files/sharepoint/WorkImages/Download/RFF-DP-11-19.pdf>, access: 2016-04-03].
11. David H A, Nagaraja H N. Order Statistics. Wiley Series in Probability and Statistics, 2003.
12. Doliński K. Comparison of stochastic model of fatigue crack growth with experiments. Fatigue Fract. Engng. Mater. Struct. 1993; 16 (10): 1021-1034.
13. Drew D R. Traffic flow theory and control. New York: McGraw-Hill Book Company, 1968; Chapter 12.
14. Euro RAP [online: <http://www.eurorap.org/>, access: 2016-04-03].
15. Ferguson T S. On the rejection of outliers. In Proc. Fourth Berkeley Symposium Math. Statist. Prob. 1961; 1: 253-287.
16. Foss S, Korshunov D, Zachary S. An Introduction to Heavy-Tailed and Sub exponential. Series in Operations Research and Financial Engineering Distributions. Springer, 2013.
17. Fronczak A, Fronczak P. Świat sieci złożonych. Od fizyki do Internetu. Warszawa: Wydawnictwo Naukowe PWN, 2009.

18. Golab L, Ozsu M T. Issues in data stream management. *ACM Sigmod Record*, 2003; 32 (2): 5-14.
19. Grubbs F E. Sample criteria for testing outlying observations. *Ann. Math. Statist.* 1960; 1: 27-58.
20. Guzewski P. Wypadki drogowe – statystyka i przyczyny. Szkolenie z zakresu ratownictwa technicznego dla Strażaków Ratownictwa OSP. Red. Surala Zb. CNBOP. 2008; 4-23.
21. Jones T R. and Potts R B. The measurement of acceleration noise – a traffic parameter. *Operations Research*, 1962; 10: 745-763.
22. Jurecki R, Jaśkiewicz M, Guzek M, Lozia Z, Zdanowicz P. Driver's reaction time under emergency braking a car – Research in a driving simulator. *Eksploatacja i Niezawodność – Maintenance and Reliability*. 2012; 14 (4): 295–301.
23. Kaczor M, Marczak M. (red.) Badanie wpływu oznakowania tyłu pojazdu na jakość ruchu. – Praca naukowo badawcza. - Etap II. Zakład Modelowania Procesów Transportowych w Instytucie Systemów Transportowych i Eksploatacji Taboru Kolejowego, WSI Radom, 1983.
24. Krzyśko M. *Mathematical Statistics*. Poznań: Wydawnictwo Naukowe UAM, 2004 (in Polish).
25. Kotulski Z, Szczepiński W. *Rachunek błędów dla inżynierów*. Warszawa: WNT, 2004.
26. Kuźmiński Ł. The application of value extreme theory in warning forecast in hydrology for sequence of independent lognormal random variables. *Studia Ekonomiczne*, 2014; 207: 148-158 (in Polish).
27. Mercedes-Benz "Intelligent Drive". TecDay. Press Information. November, Daimler Communications, 70546 Stuttgart Germany, 2012 [online: https://www.mbusa.com/vcm/MB/DigitalAssets/AboutUs/PressRelease/PM_TecDay_Intelligent_Drive_en.pdf, access: 2016-04-03].
28. Murzewski J. *Niezawodność konstrukcji inżynierskich*. Warszawa: Arkady, 1989.
29. Patel J, Kapadia C H, Owen D B. *Handbook of statistical distribution*. Marcel Dekker, 1976.
30. Rousseeuw P, Leroy A. *Robust Regression and Outlier Detection*. John Wiley & Sons, 2003.
31. Sakamoto Y, Ishiguro M, Kitagawa G. *Akaike Information Criterion Statistics*. Tokyo: Reidel Publishing Company, 1986.
32. Srivastava M S, Von Rosen D. Outliers in Multivariate Regression Models. *J. Mult. Anal.* 1998; 65: 195-208.
33. Suchodolski S. Probabilistyczna ocena wytrzymałości włókien szklanych oraz połączenia włókno-spoivo epoksydowe na podstawie testu fragmentacji. *Prace XVII Sympozjum Mechaniki Eksperymentalnej Ciała Stałego*, Jachranka 1996, 550-557.
34. Wicher J. *Bezpieczeństwo samochodów i ruchu drogowego*. Warszawa: Wydawnictwa Komunikacji i Łączności, 2012.

35. Woch J. Teoria potoków ruchu. Katowice: Zakład Inżynierii Ruchu Instytutu Transportu, 2001 [online: http://dydaktyka.polsl.pl/kir/TPR_WWW/TPR.htm, dostęp: 2016-04-03].

dr hab. Andrzej Kornacki

dr hab. Jacek Wawrzosek

dr Andrzej Bochniak

Katedra Zastosowań Matematyki i Informatyki

Uniwersytet Przyrodniczy w Lublinie

ul. Głębocka 28, 20-612 Lublin, Polska

E-mails: andrzej.kornacki@up.lublin.pl,

jacek.wawrzosek@up.lublin.pl, andrzej.bochniak@up.lublin.pl

dr hab. inż. Andrzej Szymanek

Instytut Systemów Transportowych i Elektrotechniki

Uniwersytet Technologiczno-Humanistyczny w Radomiu

ul. Malczewskiego 29, 26-600 Radom, Polska

E-mail: a.szymanek@uthrad.pl

dr hab. Halina Pawlak

Katedra Podstaw Techniki Zakład Ergonomii

Uniwersytet Przyrodniczy w Lublinie

ul. Głębocka 28, 20-612 Lublin, Poland

E-mail: halina.pawlak@up.lublin.pl
