

SYSTÉMY PRE ZVÝŠENIA BEZPEČNOSTI VODIČA MOTOROVÉHO VOZIDLA - ZAZNAMENÁVANIE OKA, POHLĀDU V REÁLNO M ČASE PRE MONITOROVANIE OSTRAŽITOSTI VODIČA

SYSTEMS DRIVERS SECURITY – EYE, REAL TIME

Rudolf Volner¹

Anotácia: Táto štúdia pojednáva o možnostiach využitia vizuálnych systémoch v dopravných technológiách. Rozoberá možnosti vizuálneho systému ako systému pre zvýšenie vonkajšej bezpečnosti tak aj systému pre počítačové pozorovanie a pre monitorovanie ostražitosti vodiča za volantom. Dôvod na skonštruovanie takéhoto systému bol hlavne predísť častým dopravným nehodám, ktorých príčina je veľmi často mikrosprávok vodiča. Práve zmenšený stupeň ostražitosti vodiča sa stal problémom vážneho záujmu pre spoločnosť.

Kľúčové slová: bezpečnosť, oko, reálny čas

Anotation: The requirements on transportation systems concern not only the quantitative and qualitative aspects of transportation activities, but still more also the aspects of their reliability and safety. Analyzing the reliability and safety of transportation, one finds that the activity of human being is the weakest point. The technical reliability of almost all the transportation tools has improved quite a lot in recent years, however the human subject interacting with them has not changed too much, as concerns his/her reliability and safety of the respective necessary interaction.

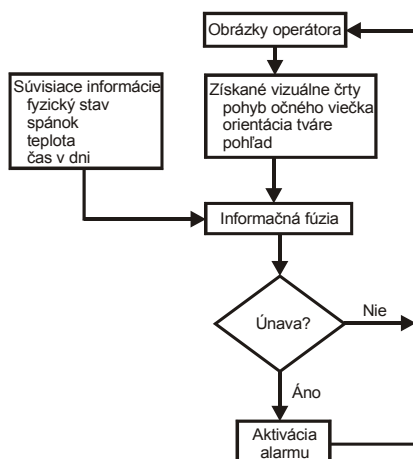
Keywords: security, eye, real time

1. ÚVOD

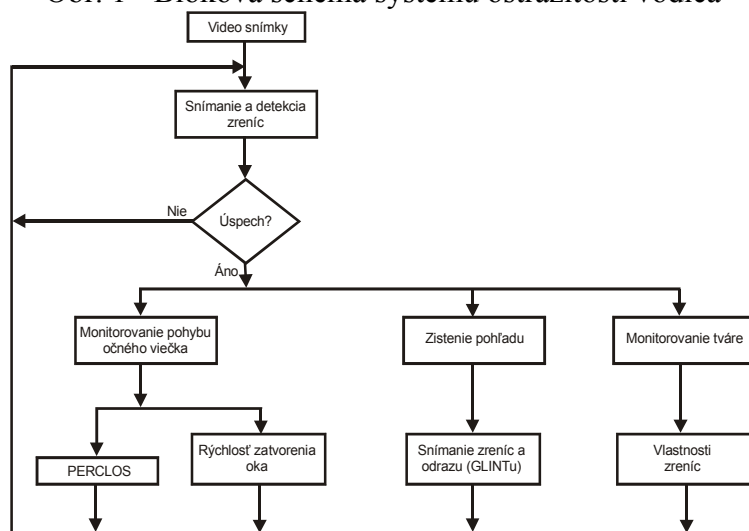
System, ktorý závisí na samotnom vizuálnom signály môže naraziť na ťažkosti, keď sa vyžadované vizuálne črty nedajú získať presne, alebo spoľahlivo. Napr., vodič s okuliarmi môže zaznamenať vážny problém pri technike založenej na detekcii charakteristík oka [10]. Okuliare môžu zapríčiniť odraz svetla, kvôli ktorému je pre kameru nemožné monitorovať pohyb očí. ďalej stupeň otvorenia oka môže byť u každého človeka iný. Ďalší potencionálny problém s využitím samotného vizuálneho signálu je, že získaná vizuálna čiara nemusí byť vždy indikátorom mentálneho stavu. Napr. nepravidelný pohyb hlavy, alebo pohľad (ako krátky pohľad dozadu alebo do spätného zrkadla) môže pre takýto systém znamenať falošný poplach.

Všetky tieto vizuálne signály, aj keď sú individuálne nedokonalé, systematickým kombinovaním poskytujú presnú charakteristiku stupňa ostražitosti vodiča.

¹ prof. Ing. Rudolf Volner, Ph.D., Department of Air Transport, Institute of Transport, Faculty of Mechanical Engineering, VŠB - Technical university of Ostrava, Tel.: +420 596 99 1765, E-mail: rudolf.volner@vsb.cz




Obr. 1 - Bloková schéma systému ostražitosti vodiča



Obr. 2 - Prehľad systému monitorovania ostražitosti vodiča

Systém začína detekciou a snímaním zreníc, čo je ďalej využívané na monitorovanie pohybu očných viečok, pohľadu a na určenie orientácie tváre.



Obr. 3 - Bloková schéma systému detekcie a snímania zreníc

2. SNÍMANIE ZRENICE POMOCOU KALMANOVEJ FILTRÁCIE

Pre nepretržité monitorovanie osoby je dôležité snímať jej/jeho zrenice v snímkoch idúcich zaradom (*frame to frame*) v reálnom čase. Dá sa to dosiahnuť vykonávaním detekcie zrenice v každej snímke. Tento spôsob je však v reálnom čase prakticky nemožné uskutočniť, pretože by sme museli prehľadávať každý jeden obrázok, v každom rade, čo je veľmi časovo náročné. Dá sa to spraviť efektívnejšie a to využitím plánu predvídania, resp. predikcie a lokalizácie.

Predvídanie znamená určenie približných polôh zreníc v ďalšom obrázku na základe normálnej polohy. Lokalizácia určuje presnú polohu pomocou lokálneho vyhľadávania. Prvý krok zaručuje presnú lokalizáciu výhodnú pre druhý krok, pretože limituje prehľadávanú plochu (robí plochu menšou) v nasledujúcich snímkoch.

Pri zavádzaní tejto schémy sa musia brať do úvahy 2 faktory veľkosti prehľadávacieho okna:

- Veľké prehľadávacie okno môže viesť k nepotrebnému prehľadávaniu a je časovo náročné,
- Príliš malé okno môže ľahšie prehliadnúť informáciu o zrenici.

Efektívne je použitie tzv. adaptívneho prehľadávacieho okna, kde plocha snímky je určená automaticky na základe veľkosti zrenice a chyby pozície, pričom podstata činnosti adaptívneho prehľadávacieho okna spočíva v Kalmanovej filtrácii. Kalmanov filter je súbor opakujúcich sa algoritmov, ktoré odhadujú pozíciu a nepresnosť pohybujúcich sa objektov v nasledujúcej snímke. To znamená: kde hľadať zrenice, aká veľká oblasť má byť prehľadávaná v nasledujúcej snímke okolo predvídanej pozície, aby sme s istotou našli zrenice. Opakovane upravuje pozíciu normálnej polohy a veľkosť prehľadávacieho okna a proces sa opakuje s predchádzajúcimi posterior odhadmi, aby sa navrhli (predikovali) nové apriori odhady. Tento proces opakovania je základná vlastnosť Kalmanovho filtra čo nám praktickú implementáciu celého systému do praxe neuveriteľne zjednodušuje.

Realizácia snímania očných zreníc založená na Kalmanovej filtrácii môže byť nasledovná.

Získame sekvenciu snímok, pričom táto sekvencia snímok je vzorkovaná v každom obrázku časom t , je ďalej spracovávaná na určenie polohy zrenice. Stav zrenice v každej časovej vzorke je charakterizovaný svojou pozíciou a rýchlosťou. Nech (c_t, r_t) predstavujú pozíciu bodu zrenice (jej stred) v čase t a nech (u_t, v_t) je jeho rýchlosť v čase t v smere c a r . Stavový vektor v čase t môžeme potom vyjadriť nasledovne

$$x_t = (c_t r_t u_t v_t)^t \quad (1)$$

V súvislosti s teóriou Kalmanovej filtrácie, stavový vektor x_{t+1} v ďalšom časovom okamihu $t+1$ lineárne závisí od stavu x_t podľa nasledovného systémového modelu

$$x_{t+1} = \Phi x_t + w_t \quad (2)$$

kde Φ - stavová prechodová matica,

w_t - predstavuje systém chýb (porúch), normálové rozdelenie

$$w_t \approx N(0, Q) \quad (3)$$

Ak predpokladáme, že pohyb zrenice medzi dvomi po sebe idúcimi snímkami je dostatočne malý na to, aby sme považovali pohyb pozícií zreníc zo snímky do snímky za rovnaký (jednotný), potom stavová matica prechodu môže obsahovať tieto parametre

$$\Phi = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (4)$$

Ďalej predpokladáme, že rýchly detektor odhadne $z_t = (\hat{c}_t, \hat{r}_t)$ predpokladanú pozíciu zrenice v čase t . Potom rozmerový model potrebný pre Kalmanov filter je

$$z_t = Hx_t + v_t \quad (5)$$

kde matica H sa vzťahuje na normálny stav pre bežné rozmery a v_t predstavuje rozmerovú nepresnosť v normálovom rozdelení $v_t \approx N(0, R)$.

Pre jednoduchosť z_t zahŕňa iba pozíciu, preto môžeme H písať

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix} \quad (6)$$

Charakteristický detektor vyhľadáva oblasť určenú kovariantnou maticou \sum_{t+1}^{-1} aby sa našiel charakteristický bod v čase $t+1$. Na produkciu finálneho odhadu je detekovaný bod skombinovaný z predpokladaným odhadom. Oblasť vyhľadávania sa automaticky mení na základe \sum_{t+1}^{-1} .

Nech x_{t+1}^{-1} je odhadovaný stav v čase $t+1$ vyplývajúci z použitia systémového modelu. Často sa označuje ako *aprior* stavový odhad. x_{t+1} sa líši od x_{t+1}^{-1} v tom, že x_{t+1} je odhadnutý pomocou oboch aj systémového modelu (2) aj rozmerového modelu (5). x_{t+1} je obyčajne označovaný ako *posterior* stavový odhad.

Nech \sum_{t+1}^{-1} a \sum_{t+1} sú kovariantné matice pre stavové odhady x_{t+1}^{-1} a x_{t+1} . Charakterizujú nepresnosti asociované aprior a posterior stavovými odhadmi. Cieľom Kalmanovej filtrácie je odhadnúť x_{t+1} a \sum_{t+1} danú x_t, \sum_t, z_t , systémový a rozmerový model. Algoritmus Kalmanovej filtrácie pre stavovú predikciu a aktualizáciu dát (*updating*) možno zosumarizovať nasledovne.

Stavová predikcia - Pri zadaní normálneho x_t a jeho kovariantnej matice \sum_t zahŕňa predikcia stavu 2 kroky:

- Určenie stavu (x_{t+1}^{-1}),
- odhadnutie chyby kovariancie (\sum_{t+1}^{-1})

$$x_{t+1}^{-1} = \Phi x_t \quad (7)$$

$$\sum_{t+1}^{-1} = \Phi \sum_t \Phi^t + Q_t \quad (8)$$

Aktualizácia dát - Pri zadaní aprior odhadu x_{t+1}^{-1} , jeho kovariantnej matice \sum_{t+1}^{-1} a normálneho rozmeru z_{t+1} vyplývajúceho z charakteristickej detekcie (buď pomocou jednoduchého prahovania, alebo korelačnou metódou) v okolí určenom \sum_{t+1}^{-1} . Aktualizácia dát môže byť uskutočnená pre odvodenie posterior stavu a jeho kovariantnej matice.

Prvou úlohou pri aktualizácii dát je vypočítať Kalmanovo zosilnenie K_{t+1}

$$K_{t+1} = \frac{\sum_{t+1}^- H^T}{H \sum_{t+1}^- H^T + R} \quad (9)$$

Matica zosilnenia K sa dá interpretovať ako záťažový faktor pre určenie rozmeru z_{t+1} a predikcie Hx_{t+1}^- ku posteriori stavového odhadu x_{t+1} . Ďalším krokom je skutočné meranie procesu určené k získaniu z_t a potom generovanie posteriori stavového odhadu x_{t+1} dosadením rozmeru do rovnice (1). x_{t+1} potom vypočítame nasledovne

$$x_{t+1} = x_{t+1}^- + K_{t+1}(z_{t+1} - Hx_{t+1}^-) \quad (10)$$

Finálnym krokom je získanie posteriori chyby kovariancie odhadu

$$\sum_{t+1} = (I - K_{t+1}H)\sum_{t+1}^- \quad (11)$$

Po každom čase a meraní Kalmanov filter rekurzívne upravuje normálny odhad všetkých minulých rozmerov a proces sa opakuje s predchádzajúcimi posterior odhadmi použitými pre určenie, alebo predikciu nového apriori odhadu.

Aby Kalmanov filter fungoval, musí byť inicializovaný. Musíme špecifikovať počiatkový stav. Kalmanov snímač spúšťame až po úspešnej detekcii zreníc v dvoch po sebe idúcich snímkoch. Nech 2 snímky sú t a $t+1$, potom počiatkový stavový vektor x_0 bude definovaný nasledovne

$$\begin{aligned} c_0 &= c_{t+1} \\ r_0 &= r_{t+1} \\ u_0 &= c_{t+1} - c_t \\ v_0 &= r_{t+1} - r_t \end{aligned} \quad (12)$$

Tak isto potrebujeme špecifikovať počiatkovú kovariantnú maticu \sum_0 pre počiatkový stav x_0 . Pretože \sum_t je opakovane aktualizovaná získavaním ďalších snímkou, môžeme ju inicializovať na veľké hodnoty. Ak predpokladáme, že predpokladaná pozícia má chybu ± 10 pixelov od skutočnej hodnoty v oboch smeroch u a v a rýchlosť má chybu ± 5 pixelov od skutočnej hodnoty v oboch smeroch u a v , potom odhadovaná kovariantná chyba je definovaná nasledovne

$$\sum_0 = \begin{bmatrix} 100 & 0 & 0 & 0 \\ 0 & 100 & 0 & 0 \\ 0 & 0 & 25 & 0 \\ 0 & 0 & 0 & 25 \end{bmatrix} \quad (13)$$

Okrem x_0 a \sum_0 odhadneme systémovú a rozmerovú chybu kovariancie matic Q a R . Na základe pozorovania pohybu zreníc môžeme s istotou predpokladať systémový model porúch nasledovným spôsobom. Nech štandardná odchýlka od systémovej chyby pozície sú 4 pixely pre oba u a v smery. Ďalej predpokladáme, že štandardná odchýlka pre rýchlostnú chybu sú 2 pixely/snímok. Potom smerová kovariantná matica je definovaná

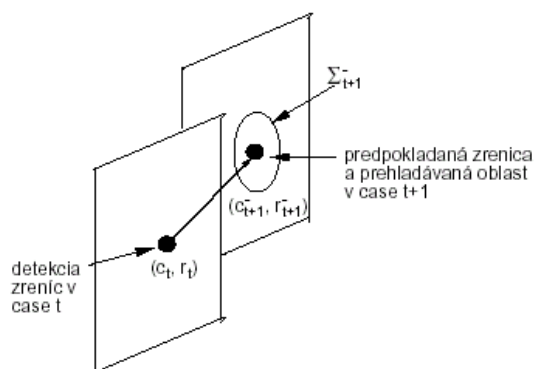
$$Q = \begin{bmatrix} 16 & 0 & 0 & 0 \\ 0 & 16 & 0 & 0 \\ 0 & 0 & 4 & 0 \\ 0 & 0 & 0 & 4 \end{bmatrix} \quad (14)$$

Podobne môžeme predpokladať chybu rozmerového modelu 2 pixely pre oba x a y smery. Potom

$$R = \begin{bmatrix} 4 & 0 \\ 0 & 4 \end{bmatrix} \quad (15)$$

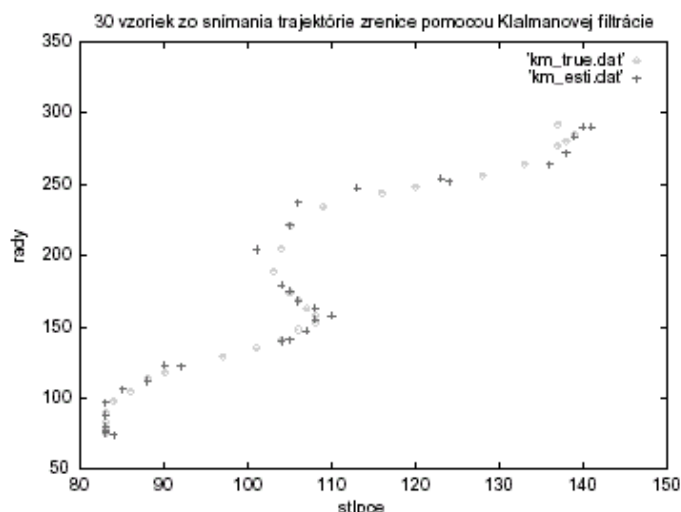
Predpokladáme, že Q a R sú konštantné matice.

Použitím stavovej predikcie a úpravou rovníc v spojení s počiatočnými podmienkami, je stavový vektor a jeho kovariantná matica každého snímku odhadnutá. Kovariantná matica Σ_t sa postupne stabilizuje po niekoľkých snímkach. Stavová kovariantná matica Σ_t udáva nepresnosť pozície zreníc v t . Vyhľadávacia plocha môže byť určená Σ_t - obr. 4. Elipsa na obrázku predstavuje prehľadávanú oblasť. Hlavná a vedľajšia os elipsy je určená 2 vektormi zo Σ_t . V praxi pre rýchlejšie vypočítanie veľkosti prehľadávanej plochy sú používané hodnoty $\Sigma_t[0][0]$ a $\Sigma_t[1][1]$. Špecificky je veľkosť prehľadávanej plochy zvolená $50 + 2\Sigma_t[0][0]$ a $50 + 2\Sigma_t[1][1]$, kde základná veľkosť okna je 50×50 . Prehľadávaná plocha je preto prispôbená. Ak snímanie zlyhá, detekcia zreníc bude reaktivovaná. Snímanie zlyhá práve vtedy, ak nasnímaná oblasť má unimodálne rozloženie intenzity, alebo ak binárna časť detekovaná v snímanej oblasti nesúhlasí s určitými geometrickými rozmermi ako sú tvar a veľkosť.



Obr. 4 - Detekcia a snímanie zreníc použitím Kalmanovej filtrácie, kde $(\hat{c}_{t+1}, \hat{r}_{t+1})$ sú predpokladané pozície a Σ_{t+1} sú neistoty súvisiace s $(\hat{c}_{t+1}, \hat{r}_{t+1})$

Pri štúdiu platnosti Kalmanovho filtra pre snímanie zreníc sme študovali rozdiely medzi predpokladanou a aktuálnou lokáciou zrenice - obr. 5.



Obr. 5 - Trajektória reálnych a odhadovaných pozícií zreníc v 30 - obrázkovej sekvencii

Krížiky znamenajú odhadnuté polohy zreníc pomocou Kalmanovho filtra a krúžky znázorňujú aktuálnu snímanú pozíciu zreníc. Z obrázka je jasné, že predpokladané a aktuálne pozície zrenice “v značnej miere“ súhlasia.

Hlavnými výhodami tohto systému detekcie a snímania očí je jeho jednoduchosť a presnosť. Nie je pozorovanému objektu na obtiaž, teda objekt môže byť snímaný a vôbec o tom nemusí vedieť.

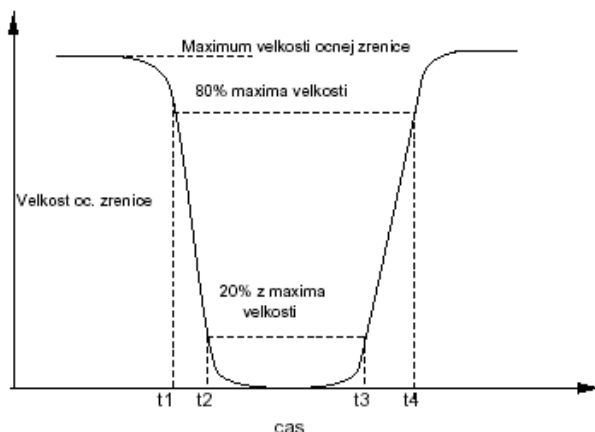
Táto technika nevyžaduje žiadny fyzický, alebo geometrický model. Je založená na spektrálnych vlastnostiach zrenice. Hoci sa vyžaduje špeciálne osvetlenie, nastavenie osvetlenia je jednoduché a pozadie je irelevantné. Zrenice môžu byť detekované a snímané v reálnom čase v širokej škále podmienok.

3. POČÍTANIE PARAMETROV POHYBU OČNÉHO VIEČKA

Pohyb očného viečka je jeden z vizuálnych prejavov, ktoré odzrkadľujú stupeň únavy osoby. Základným cieľom snímania zreníc je monitorovanie pohybu očného viečka a vypočítanie relevantných parametrov pohybov. Existuje niekoľko rozmerov charakterizujúce pohyb očného viečka ako frekvencia žmurkania, trvanie zavretia oka, rýchlosť zatvárania oka a parameter *Perclos*. *Perclos* meria percento zatvorenia oka v čase a zahŕňa čas potrebný na normálne zavretie. Ďalším vizuálnym parametrom pre identifikovanie únavy vodiča je rýchlosť zatvárania/otvárania oka, čím rozumieme čas potrebný na úplné zatvorenie a úplné otvorenie očí.

Pre získanie týchto 2 parametrov (*Perclos* a rýchlosť zatvárania očí) predpokladáme kontinuálne snímanie zreníc objektu a determináciu (určenie) počtu zavretí očí v reálnom čase založenú na ploche zreníc, ktoré boli zatvorené očnými viečkami. Zatvorenie oka sa znižuje, keď sa veľkosť detekovanej zrenice znižuje na zlomok nominálnej veľkosti (20%). Individuálne trvanie zatvorenia oka je definované ako časový rozdiel medzi dvoma po sebe idúcimi časovými okamihmi t_2 a t_3 , medzi ktorými je veľkosť zrenice 20%, alebo menej z maximálnej veľkosti. Individuálna rýchlosť zatvorenia oka je definovaná ako časová


perióda od t_1 po t_2 , alebo od t_3 po t_4 , počas ktorej je veľkosť zrenice medzi 20% a 80% nominálnej veľkosti – obr. 6.



Obr. 6 - Závislosť veľkosti očnej zreničky od času

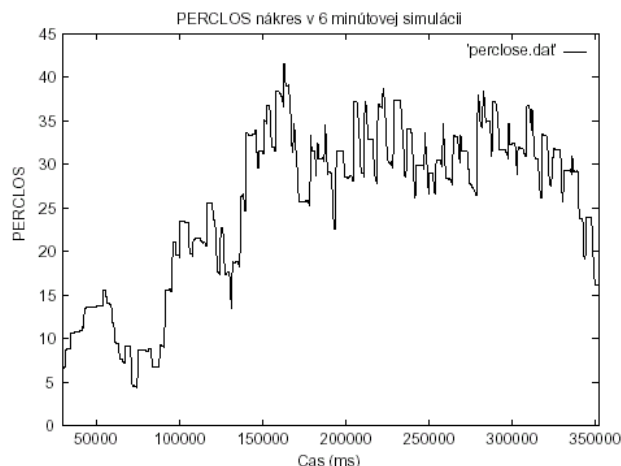
4. ANALÝZA VÝSLEDKOV SIMULOVANIA ZATVÁRANIA OKA

V tejto časti budú popísané experimenty uskutočnené za cieľom štúdia platnosti dvoch pohybových parametrov oka. Aby sme získali skutočne reálne údaje, ľudský objekt schválne rôzne žmurká očami pred zhotoveným systémom, aby simuloval rôzne vzorky pohybu očných viečok, ktoré predstavujú rôzne stupne únavy. Treba si uvedomiť, že nemeríme únavu samotnú, ale rôzne vzorky pohybu očných viečok.

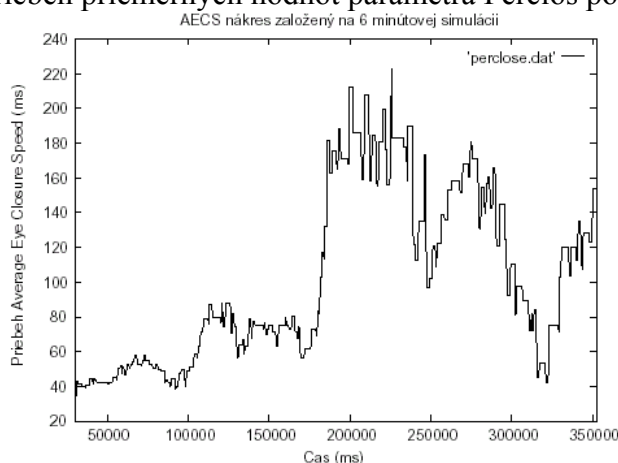


Obr. 7 - Porovnanie rýchlostí zatvárania oka

Z grafu vidno, že zatváranie oka osoby ktorá je čulá trvá 0,17s, kde u ospalého/unaveného človeka trvá zatváranie oka až 1,68s. Aj tento fakt nám naznačuje, že rýchlosť zatvorenia oka môže byť potenciálne využitá ako veličina, ktorá presnejšie určuje stupeň únavy vodiča.

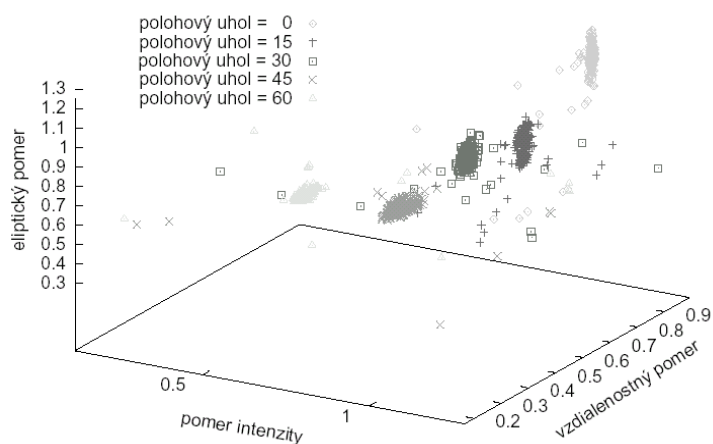


Obr. 8 - Priebek priemerných hodnôt parametra Perclos počas 6 minút

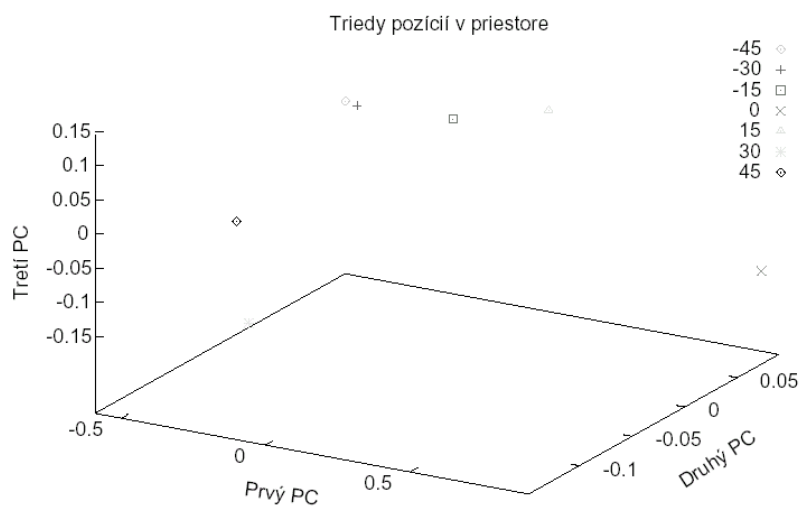


Obr. 9 - Priebek AECS priemerných hodnôt počas 6 minút

Obr. 10 zobrazuje priemety vzoriek dát do PFS (*Pupil Feature Space* - priestor charakteristických črt (vlastností) zreníc), z ktorého jasne môžeme vidieť, že je tu 5 odlišných skupín zodpovedajúcich piatim orientáciám tváre. Treba poznamenať, že hoci vieme nakresliť 3D priestor, PFS je tvorený siedmimi znakmi, v ktorom sa skupiny budú viac odlišovať, takže poloha môže byť určená premietnutím vlastností zreníc do PFS.



Obr. 10 - Skupiny pozície tváre v priestore charakteristických znakov zreníc



Obr. 11 - Projekcia tried v PFS

Pre maximálne rozdelenie rôznych skupín potrebujeme znázorniť PFS, v ktorom rôzne triedy pozícií sú najlepšie od seba odlišené. Veľmi známi je algoritmus principiálnych komponentov PCA (*Principal Component Algorithm*), alebo priestorový algoritmus, ktorého cieľom je nájsť hlavné zložky rozdelenia plôch, alebo vektory kovariantnej matice súborov polohy. Vektory sú zoradené a každý sa týka iného množstva variácii polôh a každá samostatná poloha sa dá presne vyjadriť ako lineárna kombinácia vektorov.

Pre vytvorenie PFS sú zhromažďované tréningové údaje a niekoľko modelov reprezentujúcich typické polohy. V našich experimentoch kolíšu pozície medzi -45 až 45 stupňov. Orientácia tváre môže byť zaradená do jednej zo skupín na základe jej Euklidovskej vzdialenosti ku strednej skupiny.

4.1 Mapovanie pohľadu

Po získaní relatívnej pozície medzi zrenicou a odrazom môže byť plocha, ktorá je koordinovaná pohľadom určená pomocou procedúry lineárneho mapovania. Konvenčný prístup mapovania pohľadu využíva iba premiestnenie stredu zrenice a pozície odrazu ako vektor zrenica – odraz. Hlavnou nevýhodou tejto metódy je, že subjekt musí nehybne držať hlavu, inak sa pozícia odrazu na obrázku zmení. V praxi je ťažké udržať hlavu v pokoji. Ak sa hlava čo len nepatrne pohne, metódou snímania pohľadu dostaneme chybný výsledok. Preto musí byť pohyb hlavy zakomponovaný v procedúre odhadu pohľadu.

V súvislosti z našim mapovaním je vektor zrenica – odraz vyjadrený

$$g = [\Delta x \Delta y g_x g_y 1] \quad (16)$$

kde Δx a Δy - premiestnenia zrenica – odraz,

g_x, g_y - súradnice odrazu.

Okrem existujúcich metód, ktoré využívajú iba Δx a Δy , náš postup obsahuje aj pozíciu odrazu. Toto efektívne znižuje vplyv pohybu hlavy.

Vektorový súčiniteľ je daný

$$c = [\alpha \beta \gamma \lambda \theta]^T \quad (17)$$

Bod pohľadu je umiestnený na jednej z deviatich pozícií pohľadu. Vektor zrenica – odraz môže byť zmapovaný do plochy snímky pomocou nasledujúcich rovníc

$$i = g.c = \alpha\Delta x + \beta\Delta y + \gamma g_x + \lambda g_y + \theta \quad (18)$$

kde i - index oblasti pohľadu od 1 do 9 predstavujúci jeden z deviatich smerov,
 $\alpha, \beta, \gamma, \lambda$, a θ - koeficienty určené kalibráciou tak ako je to popísané ďalej.

4.2 Kalibrácia

Procedúra kalibrácie je veľmi jednoduchá a krátka. Rozdelíme kalibračný panel na 9 oblastí reprezentujúcich 9 smerov pohľadu. Počas kalibrácie je potrebné, aby bol fixovaný pohľad na cieľ 1 až 27. Po každom pohľade spustí systém pípanie, aby upozornil používateľa, že má zmeniť pohľad na iný cieľ. Pri každej fixácii sú spočítané a uložené 3 skupiny vektorov zrenica–odraz, takže získame maticu A 27 x 5.

Transformácia matice A na cieľový vektor B je daná

$$A.c = B \quad (19)$$

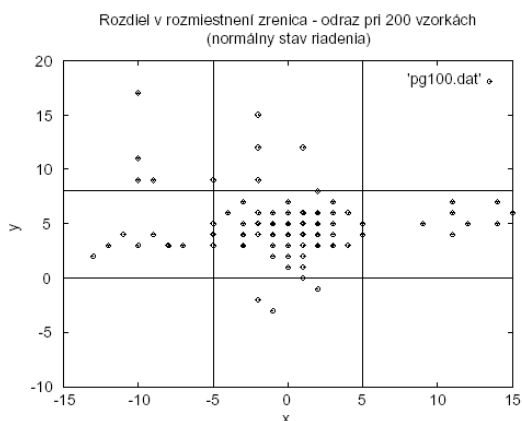
kde matica A je matica 27 x 5

$$A = \begin{bmatrix} \Delta x_1 & \Delta y_1 & g_{x_1} & g_{y_1} & 1 \\ \Delta x_2 & \Delta y_2 & g_{x_2} & g_{y_2} & 1 \\ \Delta x_3 & \Delta y_3 & g_{x_3} & g_{y_3} & 1 \\ \Delta x_4 & \Delta y_4 & g_{x_4} & g_{y_4} & 1 \\ \Delta x_5 & \Delta y_5 & g_{x_5} & g_{y_5} & 1 \\ \Delta x_6 & \Delta y_6 & g_{x_5} & g_{y_5} & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \Delta x_{25} & \Delta y_{25} & g_{x_{25}} & g_{y_{25}} & 1 \\ \Delta x_{26} & \Delta y_{26} & g_{x_{26}} & g_{y_{26}} & 1 \\ \Delta x_{27} & \Delta y_{27} & g_{x_{27}} & g_{y_{27}} & 1 \end{bmatrix} \quad (20)$$

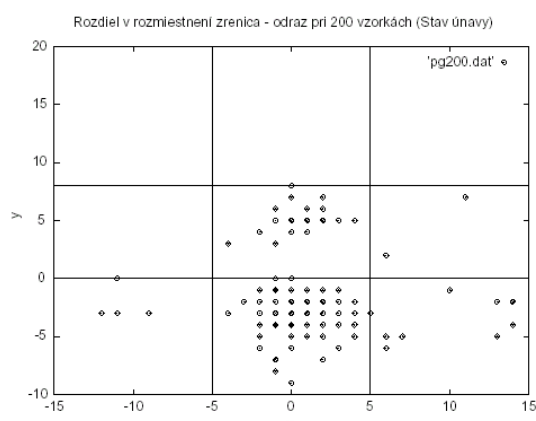
a B je 27 x 1 vektor daný

$$B = [1 \ 1 \ 1 \ 2 \ 2 \ 2 \ 3 \ \dots \ 9 \ 9 \ 9]^T \quad (21)$$

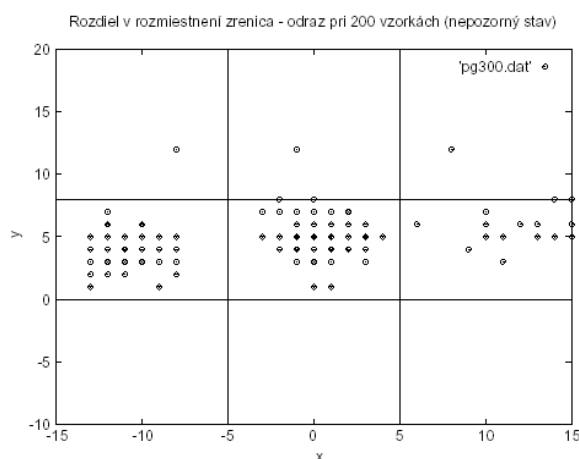
Vektorový súčiniteľ získame vyriešením rovnice (19) použitím metódy najmenších štvorcov.



Obr. 12 - Normálny stav riadenia



Obr. 13 - Stav únavy



Obr. 14 - Stav nepozornosti

5. ZÁVER

Opisovaný systém je systém počítačového vizuálneho systému pre monitorovanie ostražitosti vodiča v reálnom čase. Cieľom je vyvinúť potrebný hardware a snímkový algoritmus, ktorý simultánne extrahuje vizuálne informácie, ktoré typicky charakterizujú stupeň únavy osoby. Sú to pohyb očného viečka, pohľad a orientácia tváre. Hlavné komponenty systému pozostávajú z hardwarového systému pre získavanie video snímkov vodiča v reálnom čase a z rozličných počítačových vizuálnych algoritmov a ich software – ových implementácií pre snímanie oka/očí, pre výpočet parametrov pohybu očných viečok, pre rozlišovanie polohy tváre a pre odhad pohľadu.

POUŽITÁ LITERATÚRA

- [1] VOLNER, R., TICHÁ, D. *Road automobile communication system – telecommunication and security system*, National Conference with International participation Automatics and Informatics'2000, October 2000, Sofia, Bulgaria, pp. 56-58, ISBN 954-9641-19-8
- [2] TICHÁ, D. *A Sensitivity Approach in Digital Filter Design*, Proceedings of 3rd International Workshop Digital Technologies 2006, Žilina, 2006, ISBN 80-8070-637-9
- [3] ISOMURA, A., HARA, T, KAMIYA, K. *Human Factors on Driver's Steering Operation*. JSAE Review, 1995. 16(1), p. 111.
- [4] WIERWILLE, W.W., et al., *Research on vehicle - based driver status/performance monitoring, development, validation, and refinement of algorithms for detection of driver drowsiness*. 1994, Departemnt of transport, Washington DC. p. 219-.
- [5] VOLNER, R. *Možnosti aplikácie CCTV pri zvyšovaní bezpečnosti riadenia motorového vozidla*, Priebežná správa o riešení vyskumného zámeru Transdisciplinárni výzkum v oblasti biomedicínskeho inženýrství, Výzkumný záměr MSM 210000012, 2002 – 2004.
- [6] MOOS, P., VOLNER, R. a kol. *Rozvoj metod systémovej analýzy, algoritmov a statistických metod pro dopravu a spoje*, Výzkumný záměr MSM 2100000024/ 2005.