

تشخیص ناهمجارتی پرواز در عملیات فرود یک هواپیما با استفاده از مدل پنهان مارکف

حسن کیقبادی^۱، دکتر سید علیرضا سیدین^۲

^{۱۲}دانشگاه فردوسی مشهد، دانشکده برق- مخابرات

چکیده - صنعت حمل و نقل هوایی به طور جدی مدیریت خطر در سفرهای هوایی را دنبال می‌کند. که هدف اصلی آن تشخیص رفتارهای غیرعادی در موقعیت‌های مختلف پرواز است. روش‌های موجود، دارای محدودیت و مبتنی بر مطالعهٔ خطرات و اندازه‌گیری پارامترهای مؤثر بر آن هستند. این پارامترها حقیقت وابستگی فرایند پرواز به تصمیمات انسانی و زمان را پوشش نمی‌دهند. در این مقاله از روشی بر اساس مدل پنهان مارکف (HMM) که از روش‌های اصلی ارزیابی موقعیت در تلفیق داده محسوب می‌شود، استفاده شده است. این روش شامل دو سطح خوشبندی مبتنی بر داده و مبتنی بر مدل است. آزمایش‌ها با داده‌های هواپیمای B_777 و متغیرهای پیش‌بینی شده در نسل آینده سیستم پخش اطلاعات پروازی (ADS_B) انجام شده است. سرعت و حساسیت بسیار بالای این روش در تشخیص تغییرات غیر عادی و مؤثر در پارامترهای پرواز هنگام فرود، در نتایج این مقاله به خوبی دیده می‌شود. مدل سازی پویا مسئله وابستگی به زمان و شرایط را حل کرده است و با توجه به تطبیق این روش با سایر سیستم‌های کنترل ترافیک هوایی، توسعه‌ی آن برای تمام موقعیت‌های پرواز به راحتی امکان‌پذیر است.

کلید واژه- الگوریتم پیشرو^۱، سیستم پخش اطلاعات وابسته به نظارت خودکار^۲، مدل مارکف پنهان^۳ HMM

است از معروف‌ترین این تلاش‌ها است. در برنامه‌های تجاری کنونی از روش تشخیص تجاوز از حدود^۴ (ED) استفاده شده است که برای تعداد معینی از پارامترهای پرواز، عبور از محدوده مجاز تشخیص و اعلام خطر می‌کند. این اعلام خطر در وقایع از قبل مطالعه شده نتیجه درست می‌دهد و نه برای تمام وقایع ممکن^۵[۲]. دیگر کارهای انجام شده در ذیل آمده است.

از آخرین تلاش‌ها برای تشخیص رفتار غیر عادی با استفاده از داده‌های FDR، بسته نرم‌افزاری گزارش صحیح^۶ است[۳]. کارهای بعدی در زمینه روش‌های داده کاوی برای تشخیص رفتار غیر عادی در سیستم‌های هواپیما بوده است. بعضی از روش‌های مبتنی بر آموزش استفاده می‌کنند، مانند سیستم نظارت قیاسی^۷ (IMS) که قابلیت کمی در به کارگیری الگوهای وابسته به زمان دارند^۸[۴]. و بقیه رویکرد غیر نظراتی دارند و بر روی کاربرد الگوریتم رشته کاوی برای داده‌های گسدسته FDR تمرکز دارند

۱. مقدمه

در طول تاریخ بهبود ایمنی سفرهای هوایی توسط شرکت‌های هواپیمایی از سخت‌ترین مباحث علمی و تکنولوژی بوده است. و پس از هر پیشرفت در استراتژی‌های کاهش خطرات، حوادث هوایی باز هم رخ داده‌اند^۹[۱]. امروزه صنعت هوایی به سمت روش‌هایی برای ایمنی پرواز حرکت می‌کند که خطرات را قبل از وقوع شناسایی و اقدام لازم را انجام دهد. اطلاعات دیجیتال ضبط کننده داده‌های پرواز^{۱۰} (FDR) به طور معمول در بسیاری از شرکت‌های هواپیمایی در پردازش‌های تشخیص خطر استفاده می‌شود. تمامی روش‌ها قابلیت استفاده از بخشی از داده‌ها پارامتر پرواز موجود در FDR را دارند.

برنامه ضمانت کیفیت فعالیت‌های پروازی^{۱۱} (FOQA) که در اروپا با نام نظارت بر داده‌های پروازی^{۱۲} (FDM) شناخته شده

^۱ Forward algorithm

^۲ Automatic Dependent Surveillance – Broadcast

^۳ Hidden Markov Model

^۴ Flight Data Recorder

^۵ Flight Operations Quality Assurance

^۶ Flight Data Monitoring

^۷ Exceedance Detection

^۸ Morning report software package

^۹ Inductive Monitoring System

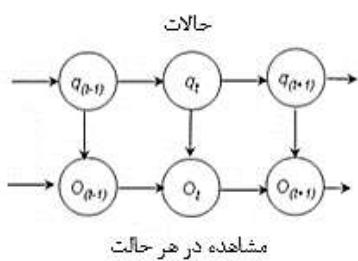
زمینه تشخیص رفتار غیر عادی فرود هواپیما در بخش ۳ و مدل‌سازی و نتایج در بخش ۵ گفته می‌شود و بحث و کارهای آینده در بخش ۶ بیان می‌شود.

۲. جایگاه HMM در تلفیق داده^{۱۳}

یکی از معروف‌ترین مدل‌های استفاده شده در مبحث تلفیق داده، مدل JDL^{۱۴} می‌باشد^[۹]. تعریف زیر توسط گروه JDL برای تلفیق داده ارائه شده است: "تلفیق داده، فرایند ترکیب داده‌ها برای بهبود تخمین و پیش‌بینی حالات است." تلفیق داده در سطوح مختلف انجام می‌شود. و کاربرد HMM مربوط به سطوح ۲ و ۳ است که برای ارزیابی وضعیت و تهدید استفاده می‌شود^[۹]. کار ارائه شده در این مقاله در واقع ارزیابی وضعیت در کاربرد فرود هواپیما است.

۳. مدل مارکف پنهان HMM^[۱۱]

HMM نوعی از فرایند تصادفی مارکف دو تایی^{۱۵} محدود است. که از دو فرایند مارکف (رنجیره مارکف) تشکیل شده است. یک فرایند با ماتریس گذر حالت و دیگری در هر حالت با یک توزیع از مشاهدات به صورت ماتریس احتمالات مشاهدات بیان می‌شود. در واقع سیستم با توزیع احتمالات گذر حالت از یک حالت به حالت دیگر می‌رود و در هر حالت شرایط سیستم به صورت سمبول‌های مشاهدات با استفاده از توزیع احتمالات مشاهدات در خروجی دیده می‌شود. بدین معنا که حالات سیستم پنهان است اما شرایط و وضعیت سیستم با مشاهدات دیده می‌شود (شکل ۱).



شکل ۱: ساختار HMM استاندارد. حالت پنهان (q_t) و مشاهده (Ot) و مشاهده در هر حالت

مانند سیستم تلنگر تعویض کابین خلبان^[۱۵]. آقای داس و همکارانش در سازمان ناسا تشخیص ناهنجاری چند هسته‌ای (MKAD)^{۱۶} را توسعه داده‌اند که از نوع تک کلاسه الگوریتم SVM^{۱۷} استفاده می‌کنند^[۶]. آقای Srivastava و همکارانش روشنی بر پایه داده معرفی کرده‌اند که با استفاده از خوشبندی به تشخیص رفتار غیر عادی می‌پردازد^[۷]. اخیراً در مقام اطلاعات الگوریتم‌های بالا به اختصار جمع‌آوری شده است^[۸].

ضرورت وجود یک سیستم با رویکرد واحد در تمام شرایط و موقعیت‌های پرواز برای تشخیص رفتار غیر عادی به شدت احساس می‌شود مخصوصاً اینکه حمل و نقل هوایی و به صورت عمومی و خصوصی به شدت در حال گسترش است. چرا که متخصصان در مراکز کنترل ترافیک هوایی فرودگاه‌ها با پارمترهای فراوان کار می‌کنند و امکان بروز خطأ وجود سیستم‌های خودکار برای هشدار به موقع خطر یک چالش مهم است. این نیاز در فرودگاه‌ها و دیگر نقاط پر ترافیک خطوط هوایی دو چندان است. یک چالش اساسی ماهیت متغیر با زمان بودن موقعیت‌های یک پرواز است بنابراین سیستم باید قابلیت تشخیص رفتار پویا را داشته باشد. و همچنین تطابق با سیستم پخش اطلاعات وابسته به نظارت خودکار (ADS_B) که در نسل آینده سیستم حمل و نقل هوایی پیش‌بینی شده است، بسیار اهمیت دارد.

در این مقاله برای تشخیص رفتار غیر عادی پرواز از متغیرهای پیش‌بینی شده در ADS_B استفاده شده است و با استفاده از مدل پنهان مارکف (HMM) رفتار عادی فرایند فرود مدل‌سازی شده و با استفاده از آن بروز هر نوع تغییر غیر عادی در متغیرهای پرواز حین فرود به سرعت تشخیص داده می‌شود و می‌تواند در هشدار قبل از وقوع حادثه برای امداد رسانی بهتر استفاده شود. این روش در مدل‌سازی فرایندهای تصادفی و بیان کارایی خیلی خوبی دارد. در واقع این کار، تلاش برای ایجاد یک چارچوب در زمینه ایجاد یک سیستم به منظور تشخیص رفتار غیر عادی پرواز بر پایه HMM است. چرا که HMM با ساختارهای متنوع و الگوریتم‌های مناسب خود به خوبی با دیگر پردازش‌ها تطبیق‌پذیر است.

در این مقاله ابتدا توضیحی برای سطح کاربرد HMM در تلفیق داده در بخش ۲، سپس بررسی نظری HMM و کاربرد در

^{۱۳}Cockpit switch flips

^{۱۴}Multiple Kernel Anomaly Detection

^{۱۵}Support Vector Machine

^{۱۶}Data Fusion

^{۱۷}Joint Director of Laboratories

^{۱۸}State

[۹] HMM اجزای یک

$\alpha_i(i)$ در الگوریتم پیشرو مقدار احتمال مشاهده یک زنجیره مشاهده O_1, O_2, \dots, O_t را در حالت i و زمان t بیان می‌کند. برای O_1 و λ به صورت زیر بدست می‌آید.

$$\alpha_i(i) = \pi_i b_i(O_1) \quad 1 \leq i \leq L \quad (7)$$

برای بقیه مشاهدات α که متغیر پیشرو گفته می‌شود به صورت زیر محاسبه می‌شود.

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^L \alpha_i(i) a_{ij} \right] b_j(O_{t+1}) \quad \begin{matrix} 1 \leq t \leq T-1 \\ 1 \leq j \leq L \end{matrix} \quad (8)$$

رابطه (8) مشخص می‌کند که چگونه به حالت s_j در زمان $t+1$ از میان N حالت ممکن می‌رسیم. محاسبات برای تمام $t = 1, 2, \dots, T$ تکرار می‌شود. جواب نهایی با جمع متغیر پیشرو^۹ پایانی برای تمام حالات بدست می‌آید رابطه (9).

$$p(O|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (9)$$

در طی محاسبات تعداد زیادی عمل ضرب بین احتمالات کمتر از یک رخ می‌دهد که باعث می‌شود جواب نهایی به صفر نزدیک شود و مشکل وقتی حادثه می‌شود که جواب نهایی از مقدار قابل نمایش کامپیوتر کمتر شود. مشکل با استفاده از یک فاکتور مقیاس c_t توسط رابطه (10) قابل حل است.

$$c_t = 1 / \sum_{i=1}^N \alpha_T(i) \quad (10)$$

و رابطه‌ای که برای محاسبات مفید است به شکل زیر است.

$$\log[p(O|\lambda)] = - \sum_{t=1}^T \log c_t \quad (11)$$

۵. آزمایش و نتایج

در این مقاله از بانک اطلاعاتی ۳۶۵ پرواز هوایی‌مای B_777 استفاده شده است، که در پروژه MKAD در سازمان ناسا نیز به کار رفته است. این داده‌ها در کنترل و هدایت پرواز توسط برج مراقبت پرواز و سیستم‌های ناوی‌گردی کاربرد دارد. داده‌ها شامل موقعیت، ارتفاع، فاصله افقی، سرعت افقی و سرعت عمودی است. در استفاده از HMM برای مدل‌سازی پدیده‌های پویا مبحث

یک HMM گستته، λ با تعداد حالات N و تعداد سمبول مشاهدات M بیان می‌شود. فضای حالات به صورت $V = \{v_1, v_2, \dots, v_M\}$ و فضای مشاهدات به صورت $S = \{s_1, s_2, \dots, s_N\}$ است. مدل λ با پارامترهای زیر توصیف می‌گردد.

$$\lambda = (\pi, A, B, N, M) \quad (1)$$

$$\pi = \{\pi_i\} = \{p(q_i = s_i)\} \quad (2)$$

$$A = \{a_{ij}\} = \{p(q_{t+1} = s_j | q_t = s_i)\} \quad (3)$$

$$B = \{b_j(k)\} = \{p(O_t = v_k | q_t = s_j)\} \quad \begin{matrix} 1 \leq i, j \leq N, \\ 1 \leq k \leq M \end{matrix} \quad (4)$$

که در روابط فوق A بیان گر احتمالات گذر حالات است، B بیان گر توزیع احتمال سمبول‌های گستته در همه حالات و π بیان گر توزیع احتمالات اولیه حالات است. a_{ij} احتمال تغییر حالت سیستم از i به j و $b_j(k)$ توزیع احتمال سمبول‌ها برای حالت j است. و حالت لحظه t با q_t و مشاهده همان لحظه با O_t نمایش داده شده است.

پارامترهای A, B, π با آموزش مدل بدست می‌آید در این مقاله آموزش با استفاده از الگوریتم حداقل‌نمایش ریاضی^{۱۰} (EM) که با نام بام ولچ^{۱۱} مشهور است انجام شده است. زمانی که λ و پارامترهای آن مشخص شد. می‌توان برای محاسبه راستی آزمایی^{۱۲} (L) از یک رشته مشاهدات استفاده شود که مقدار آن از رابطه (5) بدست می‌آید.

$$L = p(O|\lambda) \quad (5)$$

۴. الگوریتم پیشرو

O رشته مشاهدات در مدت زمان T است $O = (o_1, o_2, \dots, o_T)$ در یک مسئله تشخیص، هدف مقایسه O با یک مدل و یافتن میزان تشابه به آن است. برای محاسبه L از الگوریتم پیشرو استفاده می‌شود.

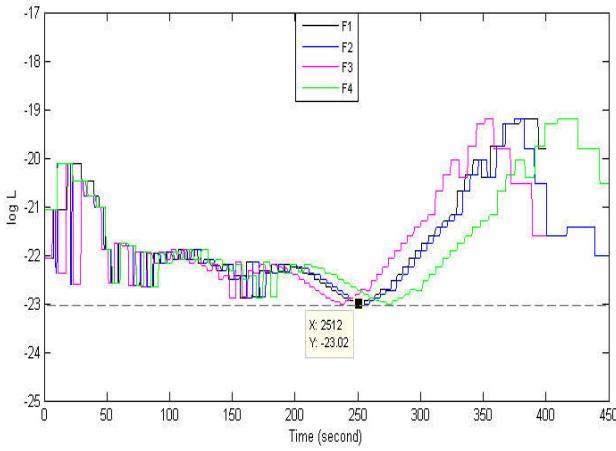
$$\alpha_t(i) = p(O_1 O_2 \dots O_t, q_t = s_i | \lambda) \quad (6)$$

^۹Expectation Maximization

^{۱۰}Baum_Welch

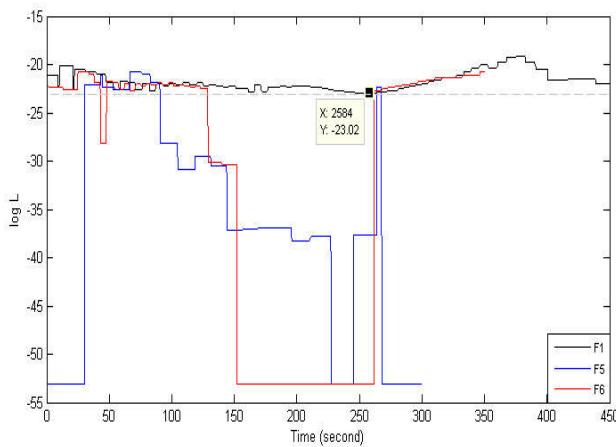
^{۱۱}Likelihood

^{۱۲}Forward variable



شکل ۲: لگاریتم L بر حسب زمان برای چهار فرود موفق و میزان حد مجاز برای L

نتایج برای ۲ فرود ناموفق و متفاوت محاسبه شد و در شکل ۳ نشان داده شده است.



شکل ۳: لگاریتم L بر حسب زمان برای یک فرود موفق ($F1$) و دو فرود ناموفق متفاوت ($F5, F6$)

فرود شماره $F5$ در ابتدا سرعت عمودی نسبت به افقی غیر عادی بوده است و سپس تنظیم شده و دواره از کنترل خارج شده است. که مدل به درستی تشخیص داده است. و فرود شماره $F6$ ابتدا با وجود داشتن ارتفاع کمتر اما با سرعت های عمودی و افقی همخوانی داشته و سپس سرعت عمودی آن از مقدار صحیح بیشتر شده و مدل آن را به درستی تشخیص داده است. زمان محاسبات به صورت آفلاین برای هر فرود بدین صورت است: $F1: ۰,۰۲۵۸۱$ ، $F5: ۰,۰۲۶۵$ و $F6: ۰,۰۲۸۳$. میزان محاسبه الگوریتم پیش رو برای ۵ سمبول به طور میانگین $۰,۰۰۰۲۸۶$ ثانیه است و با توجه به سرعت تشخیص بسیار بالا پردازش برخط در عمل به راحتی امکان پذیر است.

آموزش مدل اهمیت بسیاری دارد. بنابراین در HMM گستته روش ایجاد سمبول از داده های پیوسته مهم می باشد. همچنین تعداد این سمبول ها در حساسیت مدل موثر است. در این مقاله از K_means مقدار متغیرها استفاده کردیم و با استفاده از الگوریتم K_means ۱۰۰ خوش تقطیع شد و سمبول ها به صورت ۱, ۲, ۳, ..., ۹۹, ۱۰۰ است.

در این مقاله از داده های فرایند فرود استفاده شد که شامل ۲۰ فرود موفق و ۱۰ فرود ناموفق است. مدل شامل دو حالت است، S_1 : عدم تغییر یا تغییرات کم در متغیرهای پرواز، S_2 : تغییر قابل توجه در متغیرهای پرواز. علت انتخاب این حالت ها ضرورت وجود ارتباط منطقی ولی پنهانی با سمبول ها است. بعد از ساخت سمبول های مشاهدات، داده های فرود موفق توسط الگوریتم baum_welch برای آموزش مدل استفاده شد. ماتریس های مدل در رابطه های (۱۱) و (۱۲) و (۱۳) قرار گرفته است.

$$\pi = \begin{bmatrix} 0.55 \\ 0.45 \end{bmatrix} \quad (12)$$

$$A = \begin{bmatrix} 0.45 & 0.55 \\ 0.61 & 0.39 \end{bmatrix} \quad (13)$$

$$B = \begin{bmatrix} 0.01 & 0.011 & 0.125 & \sim 0 \\ 0.01 & 0.011 & \cdots & 0.124 \\ \sim 0 & \sim 0 & \sim 0 & \sim 0 \end{bmatrix} \quad (14)$$

بعد از ساخت مدل رفتار عادی فرایند فرود، حال باید با استفاده از داده های فرود موفق و ناموفق به تشخیص رفتار غیر عادی پرداخت برای این کار از الگوریتم پیش رو استفاده شد به این صورت که سمبول های هر فرود به عنوان ورودی به مدل داده شد و خروجی الگوریتم (L) میزان شباهت این فرود به مدل فرود موفق است. با بررسی متوجه شدیم که یک روش مناسب برای محاسبه و نمایش L استفاده از یک پنجره ۵ سمبولی بر روی داده ها است که بر روی سمبول ها تک تک حرکت کند بنابراین الگوریتم پیش رو برای ۵ سمبول اجرا شد. این کار، سرعت پردازش ها را نیز بیشتر کرد.

نتایج برای ۴ فرود موفق و متفاوت رسمند و در شکل ۲ می بینید. با بررسی تمام داده های فرود موفق یک حد برای میزان $\log(L)$ بدست آوردیم، بنابراین $-23.02 < L < -23.02$ بیان گر رفتار غیر عادی و $L > -23.02$ بیان گر رفتار عادی در هنگام فرود است.

- [7] A. Srivastava, "Discovering system health anomalies using data mining techniques," *M. F. NASA Ames Research Center, CA, United States*, 2005.
- [8] B. L. Matthews, S. Das, K. Bhaduri, K. Das, R. Martin, N. C. Oza, et al., "Discovering Anomalous Aviation Safety Events Using Scalable Data Mining Algorithms," *Journal of Aerospace Information Systems*, vol. 11, p. 482, 2014.
- [9] S. Das, *High-Level Data Fusion*: AR TECH HOUSE, 2008.
- [10] J. Holsopple, S. J. Yang, and M. Sudit, "TANDI: Threat assessment of network data and information," in *Defense and Security Symposium*, 2006, pp. 624200-624200-12.
- [11] L. R. Rabiner, "A tutorial on hidden Markov models and selected applications in speech recognition," *Proceedings of the IEEE*, vol. 77, pp. 257-286, 1989.

اصلی ترین تمایز این روش با روش MKAD و ED و روش خوشه‌بندی آقای Srivastava و همکاران استفاده از مدل سازی پویا در کنار خوشه‌بندی داده‌ها است که علاوه بر بالا بردن دقت و سرعت، امکان آموزش مدل به صورت برخط و بهبود آن نیز وجود دارد. همچنان دقت این مدل به نوع پیوسته یا گستته بودن داده‌ها وابسته نیست.

۶. بحث و نتیجه گیری

استفاده از HMM برای مدل‌سازی رفتار غیرعادی پرواز موضوع اصلی این مقاله است. این روش با توجه به کاربردش در پردازش‌های گفتار و ویدئو و مدل‌سازی پدیده‌های پویا همان‌طور که انتظار می‌رفت از دقت و حساسیت بالایی در این کاربرد نیز برخوردار است. با توجه به کاربرد اصلی HMM در مدل‌سازی و تشخیص پدیده‌های پویا و تصادفی، نتایج نشان می‌دهد این مدل برای مسئله‌ی تشخیص فرایند پرواز که پویا و وابسته به زمان است، بسیار مناسب است. و با توجه به ماهیت کاربرد که مسئله خوشه‌بندی است در مقایسه با کارهای پیشین از دو سطح خوشه‌بندی استفاده می‌کند در سطح داده علاوه بر تبدیل داده‌های زیاد به یک رشته سمبول، حدود پارامترهای پرواز را نیز مشخص می‌کند و در سطح مدل با ایجاد مدل احتمالاتی و پویا از فرود موفق، قابلیت بالایی در به کارگیری الگوهای وابسته به زمان دارد. سرتع特 بالای الگوریتم‌ها اجرای عملی پروازه را امکان‌پذیر می‌کند. این مدل برای بخش‌های مختلف یک پرواز و مطابق با شرایط مختلف آب و هوایی و نوع هواییما قابل توسعه است.

۷. مراجع

- [1] T. J. Logan, "Error prevention as developed in airlines," *International Journal of Radiation Oncology* Biology* Physics*, vol. 71, pp. S178-S181, 2008.
- [2] L. Li, S. Das, R. John Hansman, R. Palacios, and A. N. Srivastava, "Analysis of Flight Data Using Clustering Techniques for Detecting Abnormal Operations," *Journal of Aerospace Information Systems*, vol. 12, pp. 587-598, 2015.
- [3] B. G. Amidan and T. A. Ferryman, "Atypical event and typical pattern detection within complex systems," *IEEE Aerospace Conference*, 2005.
- [4] D. L. Iverson, "System health monitoring for space mission operations," *IEEE Aerospace Conference*, 2008, pp. 1-8.
- [5] S. Budalakoti, A. N. Srivastava, and M. E. Otey, "Anomaly detection and diagnosis algorithms for discrete symbol sequences with applications to airline safety," *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, vol. 39, pp. 101-113, 2009.
- [6] S. Das, B. L. Matthews, A. N. Srivastava, and N. C. Oza, "Multiple kernel learning for heterogeneous anomaly detection: algorithm and aviation safety case study," in *Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining*, 2010, pp. 47-56.