


Innovation for judicial process



ผศ.ดร.อานนท์ ศักดิ์วรวิชญ์

หลักสูตร Business Analytics and Data Science
สาขาวิชาวิทยาการประกันภัยและการบริหารความเสี่ยง
คณะสถิติประยุกต์ สถาบันบัณฑิตพัฒนบริหารศาสตร์

**Digital
Transformation**

- Leverage emerging technologies to build new business systems, business models, consumer & employee experience

Digitalization

- Improve business processes by leveraging digital technologies (e.g. APIs, data, cloud etc.)

Digitization

- Transition from analog to digital.




Fig. 1 The Internet of Events (IoE) is based on the Internet of Content (IoC), the Internet of People (IoP), the Internet of Things (IoT), and the Internet of Locations (IoL)

CONFIGURATION



PROFIT MODEL

The **New York Times** pivoted from its traditional ad-driven media model to digital user subscriptions.

**The
New York
Times**



STRUCTURE

Google's "20% rule", which allowed employees to work on side projects, led to the creation of Gmail and Google News.

Google



NETWORK

Henry Ford was one of the first industrialists to control his entire supply chain, a strategy later called vertical integration.



PROCESS

McDonald's franchisees were encouraged to develop and launch their own new food items, leading to wins such as the Egg McMuffin.



OFFERING



PRODUCT PERFORMANCE

Spotify created a seamless music streaming product that lapped competitors in terms of speed, responsiveness, and user experience.



PRODUCT SYSTEM

Apple has built an extensive ecosystem of products that work together, creating additional value for users.



EXPERIENCE



SERVICE

Amazon Prime comes with free expedited shipping, which can have products come as fast as within 2 hours in some metro areas.



BRAND

Patagonia's brand activism and links to environmental causes gives it a unique position in the outdoor apparel market.



CHANNEL

Nespresso locks in customers with its Nespresso Club, as well as through ongoing sales of single-use coffee pods.




CUSTOMER ENGAGEMENT


Mercedes has launched an augmented reality owner's manual that replaces its bulky predecessor while also highlighting driver and car data.





Mercedes-Benz









VELOCITY

Speed at which data are generated and analyzed

Different types and forms of data, including large amounts of unstructured data

VARIETY

VALUE

Potential of big data for socio-economic development

Level of quality, accuracy and uncertainty of data and data sources

VERACITY

VOLUME

Vast amounts of data generated through large-scale datafication and digitization of information

Roles of data science in Judicial process

- Facilitate fairness
- Detect anomaly and fraud
- Prevent crime and anomaly
- Regulatory Impact Assessment

Equality doesn't mean Justice





This is Equality



This is Justice

Test Fairness




Differential Item Functioning






Differential Prediction in the Use of the SAT and High School Grades in Predicting College Performance: Joint Effects of Race and Language

Oren R. Shewach, *University of Minnesota*, Winny Shen, *University of Waterloo*
Paul R. Sackett and Nathan R. Kuncel, *University of Minnesota*




Hispanic-White Comparisons



Asian-White Comparisons



White Comparisons



Sex Bias in Graduate Admissions: Data from Berkeley

Measuring bias is harder than is usually assumed, and the evidence is sometimes contrary to expectation.

P. J. Bickel, E. A. Hammel, J. W. O'Connell

	Applicants	Admitted
Men	8442	44%
Women	4321	35%

Dr. Bickel is professor of statistics, Dr. Hammel is professor of anthropology and associate dean of the Graduate Division, and Mr. O'Connell is a member of the data processing staff of the Graduate Division, at the University of California, Berkeley 94720.

female applicants. About 44 percent of the males and about 35 percent of the females were admitted. Just this kind of simple calculation of proportions impels us to examine the data further. We will pursue the question

would occur by chance alone. The chi-square value for this table is 110.8, and the probability of a chi-square that large (or larger) under the assumptions noted is vanishingly small.

We should on this evidence judge

SCIENCE, VOL. 187

Table 1. Decisions on applications to Graduate Division for fall 1973, by sex of applicant—naïve aggregation. Expected frequencies are calculated from the marginal totals of the observed frequencies under the assumptions (1 and 2) given in the text. $N = 12,763$, $\chi^2 = 110.8$, d.f. = 1, $P = 0$ (18).


Applicants	Outcome				Difference	
	Observed		Expected			
	Admit	Deny	Admit	Deny	Admit	Deny
	Men	3738	4704	3460.7	4981.3	277.3
Women	1494	2827	1771.3	2549.7	— 277.3	277.3

Department	Men		Women	
	Applicants	Admitted	Applicants	Admitted
A	825	62%	108	82%
B	560	63%	25	68%
C	325	37%	593	34%
D	417	33%	375	35%
E	191	28%	393	24%
F	373	6%	341	7%

Table 2. Admissions data by sex of applicant for two hypothetical departments. For total, $\chi^2 = 5.71$, d.f. = 1, $P = 0.19$ (one-tailed).

Applicants	Outcome				Difference	
	Observed		Expected			
	Admit	Deny	Admit	Deny	Admit	Deny
<i>Department of machismatics</i>						
Men	200	200	200	200	0	0
Women	100	100	100	100	0	0
<i>Department of social warfare</i>						
Men	50	100	50	100	0	0
Women	150	300	150	300	0	0
<i>Totals</i>						
Men	250	300	229.2	320.8	20.8	— 20.8
Women	250	400	270.8	379.2	— 20.8	20.8

Student admissions at UC Berkeley







Fig. 1. Proportion of applicants that are women plotted against proportion of applicants admitted, in 85 departments. Size of box indicates relative number of applicants to the department.

There is no crime without any trace!


- Large deviation from normal or average man or cluster.
- Large deviation from past behavior.
- Inconsistency with themselves and surroundings.
- Repeated anomaly pattern.
- Caution on statistical detection of cheating and anomalous detection

Large deviation from normal or average man or cluster.

Outlier Analysis




Large deviation from normal or average man or cluster.




Large deviation from past behavior.

$$\text{Loss}_{58} = f(\text{Frequency}_{57}, \text{Severity}_{57}, \text{ICD-10}_{57}, \text{ICD-9}_{57}, \\ \text{ICD-10}_{58}, \text{ICD-9}_{58}, \text{age}, \text{gender})$$



Large deviation from past behavior.



Inconsistency with themselves and surroundings.

- Low ability test taker can answer difficult item.
- K-index for copying! Eight dimensions
- Scoring test with contaminated response vector
- Influence function + Robust estimators


ฝั่งห้อง B309-310

ด้านหน้าห้อง


ປະຕູ


A1	B1	A2	B2	A3	B3	A4	B4	A5	B5	A6	B6	A7	B7	A8	B8
A16	B16	A15	B15	A14	B14	A13	B13	A12	B12	A11	B11	A10	A10	A9	B9
A17	B17	A18	B18	A19	B19	A20	B20	A21	B21	A22	B22	A23	B23	A24	B24
A32	B32	A31	B31	A30	B30	A29	B29	A28	B28	A27	B27	A26	B26	A25	B25
A33	B33	A34	B34	A35	B35	A36	B36	A37	B37	A38	B38	A39	B39	A40	B40
A48	B48	A47	B47	A46	B46	A45	B45	A44	B44	A43	B43	A42	B42	A41	B41
A49	B49	A50	B50	A51	B51	A52	B52	A53	B53	A54	B54	A55	B55	A56	B56
A64	B64	A63	B63	A62	B62	A61	B61	A60	B60	A59	B59	A58	B58	A57	B57

ປະຈຸ



Pseudovalue Distribution for an Optima Examinee






		รถตู้นายก		
		เปลี่ยน	ไม่เปลี่ยน	
ผลสลากตรง	ตรง	8	0	8
กับทะเบียน?	ไม่ตรง	24	31	55
		32	31	63

Repeated anomaly pattern.

Probability




$$Y = \begin{cases} 0 & \text{normal claim} \\ 1 & \text{Abuse claim} \end{cases} \quad \text{จาก สฟตร.}$$

$$Y = \text{ICD}_{10}, \text{ICD}_9, \text{TMT}, \text{gender}, \text{age}, \text{Severity}_{t-1}, \text{Frequency}_{t-1}, \text{Severity}_t, \text{Frequency}_t$$

Caution on statistical detection of cheating

		สภาพความเป็นจริง (State of Nature)	
		มีไฟไหม้จริง	ไม่มีไฟไหม้
การจำแนก (Classification)	สัญญาณดัง	จับสัญญาณได้ถูก (Hit)	เกิดสัญญาณเตือนผิดพลาด (False Alarm)
	สัญญาณไม่ดัง	พลาดการจับสัญญาณ (Miss)	ปฏิเสธอย่างถูกต้อง (Correct Rejection)

Performance



Cutoff 1 Cutoff2

Predictor

ตารางที่ 1 ความไว ความจำเพาะ ผลบวกปลอม และผลลบปลอมในการตรวจวินิจฉัยโรค

		การเป็นโรค	
		เป็นโรค	ไม่เป็นโรค
ผลการตรวจ	+	ความไว (Sensitivity)	ผลบวกปลอม (False Positive)
	-	ผลลบปลอม (False Negative)	ความจำเพาะ (Specificity)

Caution on statistical detection of cheating

ตารางที่ 2 ความไว ความจำเพาะ ผลบวกปลอม และผลลบปลอมในการตรวจวินิจฉัยโรคเอดส์จากเยื่อหุ้มกระพุ้งแก้ม

		การเป็นโรค	
		HIV+	HIV-
ผลการตรวจ	HIV+	997 (99.7%)	3 (0.3%)
	HIV-	3 (0.3%)	997 (99.7%)


- Positive Predictive Value: PPV

ความไว*ความซุก

$$\frac{\text{ความไว} \times \text{ความซุก}}{(\text{ความไว} \times \text{ความซุก}) + (1 - \text{ความไว}) \times (1 - \text{ความซุก})}$$

$$\frac{.997 \times .0055}{(.997 \times .0055) + (1 - .997) \times (1 - .0055)}$$

64.76 %



$$\frac{.997 \times .30}{(.997 \times .30) + (1 - .997) \times (1 - .30)}$$

99.30%

Caution on statistical detection of cheating

- Statistical evidence as a red flag or warning
- Physical evidence is always needed.
- Early detection, protection, and prevention.
- Bayesian flip is needed.

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

$P(\text{Cheating=Yes} \mid \text{Detection=Yes})$


$P(\text{Detection=Yes} \mid \text{Cheating=Yes})$

$P(\text{Cheating=No} \mid \text{Detection=No})$

$P(\text{Detection=No} \mid \text{Cheating=No})$

$$P(\text{Cheating=Yes} \mid \text{Detection=Yes}) = \frac{P(\text{Detection=Yes} \mid \text{Cheating=Yes}) * P(\text{Cheating=Yes})}{P(\text{Detection=Yes})}$$

การสร้างแบบจำลองรายการชำระเงินผิดปกติของ กรมธรรม์ประกันชีวิตโดยใช้เทคนิค **Local Outlier Factor(LOF)**



ประกันชีวิตพื้นฐาน




การฟอกเงินในประกันชีวิต

ตัวอย่างการฟอกเงินในประกันชีวิต

- ซื้อกองทุนลงทุนประกันชีวิตที่จ่ายครั้งเดียว (มีความเสี่ยงที่จะฟอกเงินมากที่สุดจากการนำเงินสกปรกก้อนใหญ่มาลงทุน)
- ซื้อประกันชีวิตรายปีที่มีการจ่ายปันผล (ได้รับเงินสะอาดเป็นงวดๆ)
- ซื้อประกันชีวิตแบบประจำที่มีเบี้ยสูง หรือเบี้ยปกติหลายกรมธรรม์ (เพื่อลดความสนใจ)
- การไถ่ถอนเงินก่อนครบสัญญา แม้จะได้เงินคืนน้อยกว่าเดิม
- ซื้อกรมธรรม์เบี้ยน้อยให้ผ่านก่อน แล้วเพิ่มเติมเบี้ย (เพื่อให้ไม่มีการตรวจสอบ)
- กู้เงินจากกรมธรรม์โดยไม่ผ่อนจ่ายคืน (ปล่อยกรมธรรม์หมดอายุไปเอง)
- เปลี่ยนมือกรมธรรม์ของเจ้าของหรือผู้รับผลประโยชน์
- ใช้กรมธรรม์เป็นหลักทรัพย์ในการกู้เงินจากธนาคาร

Global versus Local Outlier





Mahalanobis Distance

K Nearest Neighbors

Cluster Analysis

Local Outlier Factor (LOF)

เป็นวิธีการที่ใช้ในการตรวจสอบค่าผิดปกติ ด้วยวิธีการ
ตรวจความหนาแน่นรอบรัศมีของจุดที่สนใจ




ข้อมูลที่มีค่าผิดปกติจะมีคะแนนที่สูง ซึ่ง
จะไม่มีเกณฑ์ในตัดที่ตายตัว

ข้อมูลที่มีค่าปกติจะมีคะแนนประมาณ 1

LOF

- $LOF = \text{Local density of } k \text{ neighbor} / \text{Local density of its own point}$
- The Higher LOF = the more extreme local outlier!!!!
- Determine sigma (radius / reachable distance around point) so that we can count k neighbor.
- Local density for point = numbers of points within reachable distance / sum of distance between points and all k neighbors



วิธีดำเนินการวิจัย



ลูกค้า 145,842 คนที่จ่ายเบี้ย 2 ปีแรก (ช่วงปี 2555 - 2557)



กระจายข้อมูลด้วยการสุ่มแบบ **Uniform dist (N,0,1)**
ทั้งหมด 8 ชุด เนื่องจากข้อมูลขนาดใหญ่เกินไป




รัน **LOF score** ซ้ำ 100 ครั้ง หาคะแนนเฉลี่ย
ของทั้ง 8 ชุดและหาเกณฑ์ในการแบ่งกลุ่ม



Cluster Analysis ด้วยวิธีการ **K-mean**

ผลการวิเคราะห์

N	145,842
Minimum	1.0529
Lower Quartile	3.8028
Mean	6.6356
Median	5.6134
Upper Quartile	8.3377
Maximum	50.6028
Skewness	1.8527
Std Dev	3.9917
Std Error	0.0105
Median + 2.5(Q3-Q1)	16.9508



สูตรคำนวณหาจุดตัด	จุดตัด	รูปแบบปกติ	รูปแบบผิดปกติ	%รูปแบบที่ผิดปกติ
Median+2.5(Q3-Q1)	16.9508	142,170	3,672	3%

ผลการวิเคราะห์

Max cluster	Cluster	Frequency	RMS Standard Deviation	Maximum Distance from Seed to Observation	Radius Exceeded	Nearest Cluster	Distance Between Cluster Centroids
3	1	3,406	0.6395	13.9509	> Radius	3	5.5332
	2	97	2.8941	28.1499	> Radius	1	7.8612
	3	169	1.4675	27.3884	> Radius	1	5.5332

Pseudo F Statistic	Observed R-Squared Over-All	Approx. Expected R-Squared Over-All	Cubic Clustering Criterion
477.1300	0.2064	0.1047	108.2590

ผลการวิเคราะห์

Cluster group	Normal	1	2	3
สัดส่วนเงินที่จ่ายจริงเมื่อเทียบกับเงินที่ต้องจ่ายสูงสุด	0.0002	-0.0207	0.0219	0.2042
สัดส่วนเงินที่จ่ายจริงเมื่อเทียบกับเงินที่ต้องจ่ายต่ำสุด	0.0003	-0.0079	-0.0291	-0.0677
จำนวนชนิดช่องทางการจ่ายผ่านตัวแทน	0.0004	-0.1296	4.1856	-0.0965
จำนวนประเภทการจ่ายแบบที่1	-0.0001	-0.2101	0.7697	3.8544
จำนวนประเภทการจ่ายแบบที่2	0.0002	-0.0965	3.2309	-0.0368
จำนวนธนาคารที่ทำการจ่าย	-0.0003	-0.1955	1.4258	3.3523
จำนวนรูปแบบการจ่ายเบี้ย	0.0001	-0.0788	1.7666	0.4684
จำนวนช่องทางที่ลูกค้าซื้อกรมธรรม์	0.0000	-0.0931	3.4216	-0.0931
จำนวนครั้งที่จ่ายเบี้ยประกันที่มีการจ่าย	-0.0003	-0.0352	0.6315	0.5852
จำนวนกรมธรรม์ที่จ่ายแบบรายปี	-0.0001	-0.0456	1.3903	0.1983
จำนวนกรมธรรม์ที่จ่ายแบบรายครึ่งปี	-0.0006	0.0012	0.1840	0.3477
จำนวนกรมธรรม์ที่จ่ายแบบรายสามเดือน	0.0000	-0.0195	0.3312	0.1681
จำนวนกรมธรรม์ที่จ่ายแบบรายเดือน	-0.0001	-0.0216	0.5261	0.1808
เบี้ยประกันทั้งปีรวมทุกกรมธรรม์ที่มีการจ่าย	-0.0003	-0.0350	1.2317	0.2602
ทุนประกันชีวิตรวมทุกกรมธรรม์ที่มีการจ่าย	-0.0008	-0.0195	1.6847	0.0972
จำนวนกรมธรรม์ที่มีการจ่าย	0	0	2	1
จำนวนลูกค้า	142,170	3,406	97	169

สรุปผลการวิเคราะห์

- Normal

กลุ่มลูกค้าที่มีจำนวนกรมธรรม์เฉลี่ยเพียง **1** กรมธรรม์ ลูกค้ามีการจ่ายเบี้ยประกันทุกชนิด (รายเดือน, รายสามเดือน, รายหกเดือนและรายปี) และเป็นการจ่ายแบบเต็มจำนวนด้วยช่องทางเดียว

- Cluster 1

มีรูปแบบเดียวกับกลุ่ม Normal

- Cluster 2

กลุ่มลูกค้าที่มีจำนวนกรมธรรม์ประกันชีวิตเฉลี่ยมากกว่า **2** กรมธรรม์ ซึ่งลูกค้าเน้นการจ่ายเบี้ยแบบรายเดือนและรายปีโดยเป็นการจ่ายแบบเต็มจำนวนในหลายๆ ช่องทางการจ่ายกับตัวแทนขายประกัน


- Cluster 3

ลูกค้าที่มีจำนวนกรมธรรม์ประกันชีวิตเฉลี่ยมากกว่า **1** กรมธรรม์ เป็นกลุ่มที่เน้นการจ่ายเบี้ยแบบรายสามเดือนและรายหกเดือนและเป็นการจ่ายแบบเกินจำนวนในหลายๆ ช่องทางการชำระเงิน เช่น เงินสดหรือบัตรเครดิต


หน้าหลัก / หนังสือพิมพ์รายวัน / บทความ / Intelligence and Information

Cyber Insurance with Blockchain Technology


เผยแพร่: 11 ก.พ. 2561 14:55 โดย: ผศ.ดร.รัฐกร พูลทรัพย์




ผศ.ดร.รัฐกร พูลทรัพย์
ผู้อำนวยการศูนย์คอมพิวเตอร์ คณะสถิติประยุกต์
สถาบันบัณฑิตพัฒนบริหารศาสตร์ (นิด้า)




เจาะลึกการนำเทคโนโลยีบล็อกเชนใช้กับด้าน
แรงงานต่างด้าว





รูปที่ 2 : การบูรณาการข้อมูลระหว่างหน่วยงานด้วยเทคโนโลยีบล็อกเชนทำให้ทุกหน่วยงานสามารถเข้าถึงข้อมูลได้



รูปที่ 4 : การบันทึกข้อมูลคำขอและจดทะเบียนแรงงานต่างด้าวด้วยบล็อกเชน



รูปที่ 5 : โรงพยาบาลสามารถเรียกดูข้อมูลประวัติการขออนุญาตของแรงงานต่างตัวและออกใบรับรองแพทย์บนบล็อกเชน

มาตรา 77 ของรัฐธรรมนูญ

การใช้เครื่องมือวิเคราะห์ผลกระทบในการออกกฎหมาย (Regulatory Impact Assessment: RIA)

นางอุษา จั่นพลอย บัญเปี่ยม
ผู้อำนวยการสถาบันวิจัยและพัฒนากระบวนการยุติธรรม

ROAD SAFETY AND DAYTIME RUNNING LIGHTS

A concise overview of the evidence

Paper presented to the Joint Meeting of the ECMT's Road Safety Committee and Committee for Road Traffic, Signs and Signals, The Hague, The Netherlands, 15 March 1989

by

M.J. Koornstra, Director

SWOV Institute for Road Safety Research, The Netherlands

Source	Method	Vehicle type	Area	Effect
Cantilli (1965, 1970)	control group	cars	New York	- 18%
Allen & Clark (1964)	before/after	buses	USA	- 12%
id.	id.	buses	Canada	- 24%
Attwood (1981)	before/after	lorries	USA	- 32%
id.	control group	taxis	USA	- 7%
Stein (1984)	control group	cars	USA	- 22%

Table 4. Effects of DRL at large fleet-owners in North-America.

R-89-4

Leidschendam, 1989

SWOV Institute for Road Safety Research, The Netherlands



springer.com



[This journal](#)

**International Journal of
Emergency Medicine**

[Toc Alerts](#)

[Submit Online](#)

[Open Choice](#)

[Int J Emerg Med.](#) 2010 Mar; 3(1): 39–43.

Published online 2010 Mar 26. doi: [10.1007/s12245-009-0151-6](https://doi.org/10.1007/s12245-009-0151-6)

PMCID: PMC2850978

PMID: [20414380](https://pubmed.ncbi.nlm.nih.gov/20414380/)

Daytime running lights in the USA: what is the impact on vehicle crashes in Minnesota?

[Michele E. Krajicek](#) and [Raquel M. Schears](#)✉

[Author information](#) ► [Article notes](#) ► [Copyright and License information](#) ► [Disclaimer](#)

Table 1

Vehicle characteristics by DRL status

	Std. DRL, year 1995+, <i>N</i> = 37,909 (%)	No std. DRL, year 1995+, <i>N</i> = 146,728 (%)
Vehicle type		
Automobile	29,750 (78.5)	97,317 (66.3)
Pickup	5,600 (14.8)	30,959 (21.1)
Van	2,559 (6.8)	18,452 (12.6)
Type of accident ^a		
Collision with vehicle	34,475 (90.9)	133,892 (91.3)
Collision with train	15 (<0.1)	30 (<0.1)
Collision with bike	358 (0.9)	1,379 (0.9)
Collision with pedestrian	230 (0.6)	911 (0.6)
Diagram ^a		
Rear end	13,721 (36.2)	52,700 (35.9)
Sideswipe passing	2,396 (6.3)	9,379 (6.4)
Left turn into oncoming	2,412 (6.4)	9,723 (6.6)
Ran off road, left side	539 (1.4)	2,145 (1.5)
Right angle	7,979 (21)	30,347 (20.7)
Right turn into cross traffic	218 (0.6)	814 (0.6)
Ran off road, right side	728 (1.9)	3,019 (2.1)
Head on	499 (1.3)	2,147 (1.5)
Sideswipe opposing	406 (1.1)	1,612 (1.1)

Assessing Violence Risk in Stalking Cases: A Regression Tree Approach

Barry Rosenfeld^{1,2} and Charles Lewis¹

Table 1. Variables Included in CART Models

Model 1	Model 2	Model 3
Age (under 30 years)	Age (under 30 years)	Age (under 30 years)
Education (<high school)	Education (<high school)	Education (<high school)
Threatened victim	Threatened victim	Threatened victim
Prior intimate relationship	Prior intimate relationship	Prior intimate relationship
Revenge motivation	Revenge motivation	Revenge motivation
	Psychotic disorder	Psychotic disorder
	Personality disorder	Personality disorder
	Substance abuse history	Substance abuse history
	Criminal history	Criminal history
		Prior violence
		Below average intelligence
		Gender
		Foreign born




Fig. 1. Tree model predicting violence: Model 1.




Fig. 3. Tree model predicting violence: Model 2.

Table 3. Logistic Regression Models

	<i>B</i>	<i>p</i>
Model 1		
Age (under 30 years)	1.01	.008
Education (<high school)	1.21	.001
Threatened victim	0.86	.03
Prior intimate relationship	1.26	.0002
Revenge motivation	0.79	.07
Model 2		
Age (under 30 years)	0.99	.01
Education (<high school)	1.28	.0007
Threatened victim	0.84	.03
Prior intimate relationship	1.42	.0002
Revenge motivation	0.52	.15
Psychotic disorder	−0.09	.79
Personality disorder	−0.11	.80
Substance abuse history	0.29	.43
Criminal history	−0.57	.12
Model 3		
Age (under 30 years)	0.93	.02
Education (<high school)	1.17	.003
Threatened victim	0.88	.03
Prior intimate relationship	1.40	.0003
Revenge motivation	0.47	.21
Psychotic disorder	−0.15	.66
Personality disorder	−0.10	.82
Substance abuse history	0.36	.33
Criminal history	−0.76	.07
Prior violence	0.40	.37
Below average intelligence	0.53	.33
Gender	−0.17	.73
Foreign born	0.04	.88

รายงานการวิจัย

โครงการวิจัยประเมินผลเพื่อปรับปรุง (Formative Evaluation)

โครงการรณรงค์ป้องกันและแก้ไขปัญหายาเสพติด TO BE NUMBER ONE

ในทูลกระหม่อมหญิงอุบลรัตนราชกัญญา สิริวัฒนาพรรณวดี

เสนอ

กรมสุขภาพจิต กระทรวงสาธารณสุข

ตัวแปร	กลุ่มบำบัดเข้ม			กลุ่มบำบัดปกติ			t-test	p-value
	N	M	SD	N	M	SD		
ความตั้งใจที่จะกลับมาเสพซ้ำ	96	10.94	5.04	324	12.52	4.37	3.01	.00
จำนวนครั้งที่เข้ารับการบำบัดฯ ระบบสมัครใจ	102	0.59	0.87	326	0.21	0.71	-4.39	.00
จำนวนครั้งที่เข้ารับการบำบัดฯ ระบบค่าย	102	0.09	0.32	326	0.03	0.18	-2.40	.02
จำนวนครั้งที่เข้ารับการบำบัดฯ ระบบบังคับ	102	0.39	0.69	326	0.39	0.97	-0.03	.98
จำนวนครั้งที่เข้ารับการบำบัดฯ ระบบต้องโทษ	102	0.11	0.37	326	0.63	0.67	7.60	.00
จำนวนครั้งที่เข้ารับการบำบัดรวม	102	1.19	1.30	326	1.27	1.47	0.50	.62
รูปแบบความผูกพันแบบมั่นคง	98	3.91	0.79	323	3.90	0.79	-0.05	.96
รูปแบบความผูกพันแบบกังวล	97	2.97	1.05	322	3.22	1.01	2.15	.03
รูปแบบความผูกพันแบบทะนงตน	97	3.14	1.05	323	3.19	0.91	0.38	.71
รูปแบบความผูกพันแบบหวาดกลัว	97	2.73	1.18	322	2.73	1.01	-0.43	.97
ความภาคภูมิใจในตนเอง	99	29.48	4.47	326	28.20	4.30	-2.59	.01
ความรู้สึกโดดเดี่ยว	99	11.07	2.30	326	10.70	1.75	-1.72	.09
ทุนทางจิตใจ	99	34.37	5.08	326	35.21	4.49	1.57	.12
พฤติกรรมเกร	99	26.37	8.00	326	29.32	6.29	3.82	.00
ความเต็มใจในการเข้ารับการบำบัด	98	8.52	1.50	324	8.26	1.51	-1.49	.14
ทัศนคติที่มีต่อโปรแกรมบำบัด	98	21.61	2.51	324	20.42	3.32	-3.27	.00
ความต่อเนื่องในการเข้ารับการบำบัด	98	12.06	1.80	32	11.19	2.26	-3.47	.00

ตารางที่ 9.2 ความแตกต่างระหว่างรายได้ช่วงที่ติดยาเสพติดของกลุ่มที่ได้รับการบำบัดเข้มข้นกับกลุ่มที่ได้รับการบำบัดปกติ

การบำบัด	รายได้ (ช่วงที่ติดยาเสพติด)			χ^2	P-value
	ไม่เกิน 10,000	มากกว่า 10,000	รวม		
บำบัดเข้มข้น	82	12	94	53.36	.000
ร้อยละ	87	13	100		
บำบัดปกติ	144	179	323		
ร้อยละ	45	55	100		
รวม	226	191	417		

ตารางที่ 9.3 ความแตกต่างระหว่างรายได้ปัจจุบันของกลุ่มที่ได้รับการบำบัดเข้มข้นกับกลุ่มที่ได้รับการบำบัดปกติ

การบำบัด	รายได้ (ปัจจุบัน)			χ^2	P-value
	ไม่เกิน 10,000	มากกว่า 10,000	รวม		
บำบัดเข้มข้น	78	17	95	16.11	.000
ร้อยละ	82	18	100		
บำบัดปกติ	298	16	314		
ร้อยละ	95	5	100		
รวม	376	33	409		

ตารางที่ 9.5 แบบจำลองทำนายความตั้งใจในการกลับมาเสพซ้ำ วิเคราะห์โดยใช้วิธี Stepwise

Model	B	Beta	SE	t	P-value
(Constant)	9.42		1.68	5.59	.00
พฤติกรรมเกเร	0.14	.21	0.03	4.35	.00
ทัศนคติที่มีต่อโปรแกรมบำบัด	-0.33	-.23	0.06	-5.29	.00
การขายยาเสพติด	1.88	.19	0.45	4.20	.00
การคล้อยตามกลุ่มอ้างอิง	0.29	.21	0.06	4.47	.00
การขายยาเสพติดเพราะสภาพแวดล้อมมียาเสพติด	1.79	.13	0.65	2.76	.01
การขายยาเสพติดเพราะมีปัญหาครอบครัว	-2.21	-.11	0.86	-2.56	.01
รูปแบบความผูกพันแบบหวาดกลัว	0.48	.11	0.19	2.45	.02

R-Square = .334 , $F_{(7,353)} = 25.294$, $p\text{-value} = .000$

ตารางที่ 9.6 แบบจำลองทำนายจำนวนครั้งที่เข้ารับการบำบัดสมัครใจ วิเคราะห์โดยใช้วิธี Stepwise

Model	B	Beta	SE	t	P-value
(Constant)	.85		.26	3.30	.001
การบำบัดแบบเข้มข้น	.41	.21	.10	4.23	.000
ความภาคภูมิใจในตนเอง	-.02	-.14	.01	-2.77	.006
การขายยาเสพติดเพราะมีปัญหาครอบครัว	.40	.13	.16	2.47	.014
การเสพยาเสพติดเพราะสภาพแวดล้อมมียาเสพติด	.25	.12	.11	2.22	.027

R-Square = .100, $F_{(4,358)} = 9.899$, $p\text{-value} = .000$

ตารางที่ 9.9 แบบจำลองทำนายจำนวนครั้งที่เข้ารับการบำบัดฯ ระบบต้องโทษบำบัด วิเคราะห์โดยใช้วิธี Stepwise

Model	B	Beta	SE	t	P-value
(Constant)	.15		.24	0.63	.528
การบำบัดแบบเข้มข้น	-.54	-.31	.09	-5.74	.000
การขยายยาเสพติด	.26	.18	.08	3.49	.001
ความภาคภูมิใจในตนเอง	.02	.14	.01	2.75	.006
รายได้ตอนติดยา	-.19	-.14	.07	-2.54	.011
การขยายยาเสพติดเพราะมีปัญหาครอบครัว	-.28	-.10	.14	-1.99	.048

R-Square = .133, $F_{(5,357)} = 10.918$, $p\text{-value} = .000$

Wiley Classics Library

DEGROOT, FIENBERG & KADANE

Statistics
and the Law

*Statistics for Social Science
and Public Policy*

Joseph L. Gastwirth
Editor

**Statistical Science
in the Courtroom**



Statistics IN THE LAW



EDITED BY

Joseph B. Kadane

Statistics for Social and Behavioral Sciences

Michael O. Finkelstein
Bruce Levin

Statistics for Lawyers

Third Edition

Springer

**Statistics for
Social Science and
Public Policy**

**Hans Zeisel
David Kaye**

Prove It with Figures

*Empirical Methods in
Law and Litigation*



David Weisburd
Chester Britt



Third Edition



JACINTA M. GAU

Statistics for Criminology and Criminal Justice



Jacinta M. Gau

Copyright © 2004 Blackwell Publishing Ltd



FRAUD ANALYTICS

USING DESCRIPTIVE,
PREDICTIVE, AND
SOCIAL NETWORK
TECHNIQUES

A GUIDE TO
DATA SCIENCE FOR
FRAUD DETECTION



BART DAESENS
VÉRONIQUE VAN VLASSELAER
WOUTER VERBEKE

WILEY

Wiley Corporate F&A

FRAUD DATA ANALYTICS METHODOLOGY

The Fraud Scenario Approach
to Uncovering Fraud in Core
Business Systems

LEONARD W. VONA

WILEY

Wiley Corporate F&A

+ website

FRAUD AND FRAUD DETECTION

A Data Analytics Approach

SUNDER GEE

WILEY





WILEY CORPORATE F&A



FORENSIC ANALYTICS

Methods and Techniques for
Forensic Accounting Investigations

MARK J. NIGRINI, PH.D.



Alan Jessop


Let the Evidence Speak

Using Bayesian Thinking
in Law, Medicine,
Ecology and Other Areas

 Springer

DATA ANALYSIS FOR CRIMINAL JUSTICE AND CRIMINOLOGY

PRACTICE & APPLICATIONS



JEROME McKEAN • BRYAN BYERS

Machine Learning Forensics for Law Enforcement, Security, and Intelligence



Jesus Mena

 CRC Press
Taylor & Francis Group
AN AUERBACH BOOK


SPRINGER BRIEFS IN LAW

Thomas Hoeren
Barbara Kolany-Raiser *Editors*

Big Data in Context

Legal, Social and
Technological
Insights

 Springer Open



*Franco Taroni
Silvia Bozza
Alex Biedermann
Paolo Garbolino
Colin Aitken*

Data analysis in forensic science

A Bayesian decision perspective

 WILEY

STATISTICS IN PRACTICE

EXPLODING DATA

RECLAIMING OUR
CYBER  SECURITY
IN THE DIGITAL AGE

MICHAEL
CHERTOFF

DATA MINING FOR INTELLIGENCE, FRAUD, & CRIMINAL DETECTION

*Advanced Analytics &
Information Sharing Technologies*

CHRISTOPHER WESTPHAL

FOUNDATIONS OF CRIME ANALYSIS

DATA, ANALYSES, AND MAPPING

JEFFERY T. WALKER AND GRANT R. DRAWVE

 National Law Enforcement Officers
MEMORIAL FUND

 CRC Press
Taylor & Francis Group

 ROUTLEDGE


INTERNATIONAL FORENSIC SCIENCE
AND INVESTIGATION SERIES

Introduction to Data Analysis with R for Forensic Scientists



James Michael Curran

 **CRC Press**
Taylor & Francis Group

NEW YORK TIMES BESTSELLER

MARC GOODMAN



FUTURE CRIMES

**Inside the Digital
Underground and the Battle
for Our Connected World**

"Addictive. . . [Goodman] wants us never to look at our cellphones
or Facebook pages in the same way again."

—*The Washington Post*

MAPPING AND ANALYSING CRIME DATA LESSONS FROM RESEARCH AND PRACTICE


EDITED BY ALEX HIRSCHFIELD AND KATE BOWERS




HANDBOOK OF DIGITAL FORENSICS OF MULTIMEDIA DATA AND DEVICES

EDITORS

ANTHONY T. S. HO & SHUJUN LI





PREDICTIVE POLICING

The Role of Crime Forecasting
in Law Enforcement Operations



Walter L. Perry, Brian McNis, Carter C. Price,
Susan C. Smith, John S. Hollywood



ANDREW GUTHRIE FERGUSON

THE RISE OF

BIG DATA

POLICING

SURVEILLANCE, RACE, AND
THE FUTURE OF LAW ENFORCEMENT

Application of **Big Data for National Security**



A Practitioner's Guide to Emerging Technologies

Content-Type: application/soap+xml; charset=utf-8

Content-Length: 3932

<?xml version="1.0"?>

<soap:Envelope soap:encodingStyle="">

<soap:Body xmlns:m="http://192.168.1.1/loc">

<m:SecurityArray>

<m:PasswordIn>*****</m:PasswordIn>

</m:SecurityArray>

</soap:Body>

Babak Akhgar, Gregory B. Saathoff, Hamid R. Arabnia,
Richard Hill, Andrew Staniforth, and Petra Saskia Bayerl



What else?

- Medical bioinformatics
 - DNA sequencing
- Image and video analytics
- Text analytics
- Social network analysis
- Voice recognition and analytics
- Data streaming and real time analytics

Diagram illustrating the flow of money and land between various entities, including a company, a hospital, a doctor, a land management department, and a land owner.

Transactions Table (Left):

เลขที่เช็ค	ลงวันที่	จำนวนเงิน
0005293	2/5/2557	2,000,000
0005342	3/6/2557	2,000,000
0005387	30/6/2557	2,000,000
0005408	18/7/2557	1,800,000
0005444	7/8/2557	1,995,000
0005493	28/8/2557	2,950,000
0005530	12/9/2557	3,950,000
0005537	ไม่ทราบ	100,000
0005739	25/9/2557	2,590,000
0005698-733	ไม่ทราบ	1,420,000
0005739	ไม่ทราบ	2,590,000
		23,395,000

Transactions Table (Bottom):

เลขที่เช็ค	ลงวันที่	จำนวนเงิน
0005692	ไม่ทราบ	25,550
0005695	ไม่ทราบ	161,243
0005697	ไม่ทราบ	197,680
0005734	ไม่ทราบ	37,571
0005740	ไม่ทราบ	500,000

Flowchart Entities and Connections:

- บริษัท (Company):**
 - Rebate 5% to **เงินสวัสดิการโรงพยาบาลขอนแก่น**
 - Connection to **กรมธนารักษ์** (Land Management Department)
- เงินสวัสดิการโรงพยาบาลขอนแก่น (Hospital Welfare Fund):**
 - Connection to **นพ. วีระพันธ์ สุพรรณไชยมาตย์** (Dr. Viraporn Suphanchoyamat)
 - Connection to **นางเจียรศิริ พงษ์พันธ์ุ** (Ms. Jirasil Pongphor)
 - Connection to **ชมรมแพทย์ชนบท** (Rural Doctors Association)
- นพ. วีระพันธ์ สุพรรณไชยมาตย์ (Dr. Viraporn Suphanchoyamat):**
 - Connection to **เจ้าของที่ดินรอบโรงพยาบาลขอนแก่น** (Landowner around Khon Kaen Hospital)
 - Connection to **นางเจียรศิริ พงษ์พันธ์ุ** (Ms. Jirasil Pongphor)
 - Connection to **กรมธนารักษ์** (Land Management Department)
 - Connection to **ชมรมแพทย์ชนบท** (Rural Doctors Association)
- นางเจียรศิริ พงษ์พันธ์ุ (Ms. Jirasil Pongphor):**
 - Connection to **กรมธนารักษ์** (Land Management Department)
 - Connection to **ชมรมแพทย์ชนบท** (Rural Doctors Association)
- กรมธนารักษ์ (Land Management Department):**
 - Connection to **ชมรมแพทย์ชนบท** (Rural Doctors Association)
- ชมรมแพทย์ชนบท (Rural Doctors Association):**
 - Connection to **บริษัท** (Company)
- เจ้าของที่ดินรอบโรงพยาบาลขอนแก่น (Landowner around Khon Kaen Hospital):**
 - Connection to **นพ. วีระพันธ์ สุพรรณไชยมาตย์** (Dr. Viraporn Suphanchoyamat)

Notes:

- โอนที่ดินให้ในนามส่วนตัว (Transfer land in personal name)
- บริจาคที่ดินในนามส่วนตัว (Donate land in personal name)
- คืนเงินยืมให้เมื่อถูกทวงถามหลังเกษียณอายุราชการ นับสิบกว่าล้านบาท (Return the loan when asked after retirement, over 100 million Baht)
- อนุญาตให้ใช้พื้นที่ที่บริจาค (Allow use of donated land)
- ส่งมอบให้? (Deliver to?)
- ?
- ?
- ?

ชื่อการรักษาประชาชน?

ชมรมแพทย์อ้าวงชนบตต้องการฆ่าปิดปากคดีหลุมดำ 5%

โรงพยาบาลศูนย์ขอนแก่นหรือไม่?

<https://mgronline.com/daily/detail/963000059121?fbclid=IwAR3dDnLVklHF->

[lid=IwAR3dDnLVklHF-](https://mgronline.com/daily/detail/963000059121?fbclid=IwAR3dDnLVklHF-)

[OX_N48jv1HF67HJM5dsDkMAqf41Snjz4w8rP3fUyUL5wCI](https://mgronline.com/daily/detail/963000059121?fbclid=IwAR3dDnLVklHF-)


เส้นทางเงินของหลุมดำแห่งการทุจริต? ที่ต้องสอบสวน ณ

โรงพยาบาลขอนแก่น

เผยแพร่: 6 ก.ค. 2563 09:29 โดย: ผศ.ดร.อานนท์ ศักดิ์วรวิชญ์

[https://mgronline.com/daily/detail/963000069099?fbclid=IwAR38MVXd9aB1EEtV9Wav2Ba3sezLttHScnGdn6mv_mPFS](https://mgronline.com/daily/detail/963000069099?fbclid=IwAR38MVXd9aB1EEtV9Wav2Ba3sezLttHScnGdn6mv_mPFSkQsEZlF2B5n2w)

[kQsEZlF2B5n2w](https://mgronline.com/daily/detail/963000069099?fbclid=IwAR38MVXd9aB1EEtV9Wav2Ba3sezLttHScnGdn6mv_mPFSkQsEZlF2B5n2w)

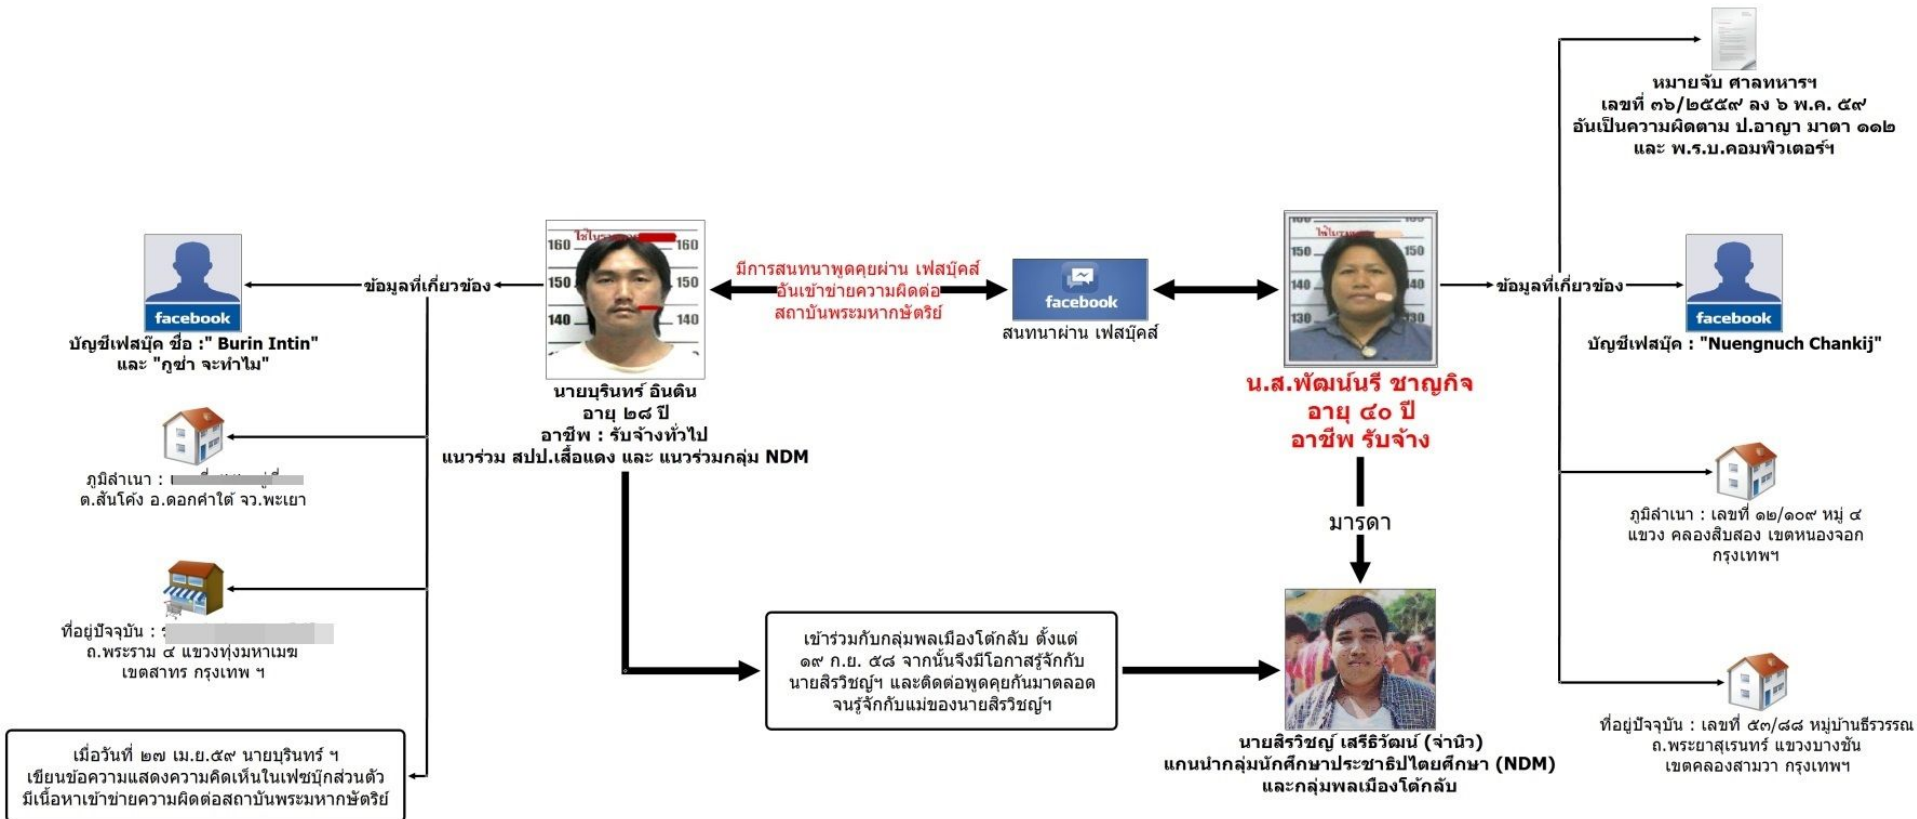


เส้นทางการเงิน 'เบนซ์ เรซซิ่ง' เกี่ยวขบวนการค้ายาเสพติด



<https://pantip.com/topic/36078982>


ผังความเชื่อมโยงระหว่าง นายบุรินทร์ฯ และ น.ส.พัฒน์นรีฯ



https://www.matichon.co.th/politics/news_128463



แผนผังความเชื่อมโยงคดีงาช้าง






Figure 1.3 First level of connections.




Figure 1.4 Money transfers related to subject.




Figure 1.5 Suspect's account receives wire transfers.




Figure 1.6 Cleaned-up interim network diagram.




Figure 1.7 Telephone toll calls.




Figure 1.8 Vehicle registration data referenced.



Leadership Development

Search now

YHOO!

AdChoices

Login

Startups

Apps

Gadgets

Videos

Audio

Extra Crunch

Newsletters

Events

Advertise


Crunchbase

More

Search 🔍

To detect fake news, this AI first learned to write it

"To know your enemy, you must become your enemy."



Defending Against Neural Fake News

Rowan Zellers[★], Ari Holtzman[★], Hannah Rashkin[★], Yonatan Bisk[★]
Ali Farhadi[▽], Franziska Roesner[★], Yejin Choi[▽]

[★]Paul G. Allen School of Computer Science & Engineering, University of Washington

[▽]Allen Institute for Artificial Intelligence

<https://rowanzellers.com/grover>

Abstract

Preprint. Under review.

Recent progress in natural language applications like summarization and machine translation also might enable adversaries to generate fake news that closely mimics the real world. Modern computer security relies on mitigations to these threats. Link-based fake news requires us first to detect the fake news. We thus present a model for detecting fake news. Given a headline like ‘Link Found Between Vaccines and Autism’, we generate the rest of the article; it is more than human-written disinformation.

Developing robust verification techniques against generators like GROVER is critical. We find that best current discriminators can classify neural fake news from real, human-written, news with 73% accuracy, assuming access to a moderate level of training data. Counterintuitively, the best defense against GROVER turns out to be GROVER itself, with 92% accuracy, demonstrating the importance of public release





Figure 1: In this paper, we explore GROVER, a model which can detect *and generate* neural fake news.



Share



Tweet



Link



Comment

MoneyOnMobile launches biometric ATM solution leveraging Aadhaar

🕒 May 24, 2018 | [Chris Burt](#)

CATEGORIES [Biometrics News](#) | [Civil / National ID](#) | [Financial Services](#)

Indian mobile payment network MoneyOnMobile has announced the launch of a biometric ATM cash-out solution, with 3,000 units activated in the initial phase, and 3,000 more expected in the coming months. Biometric MOM ATMs leverage the company's banking partners' Open Banking APIs and the Aadhaar national ID, enabling consumers to withdraw money with a fingerprint rather than a debit card.

MOST READ THIS WEEK

[JetBlue rolls out biometric boarding at JFK and DCA](#)

["Smile-to-Pay" facial recognition system now at 300 locations in China](#)



Big Brother facial recognition needs ethical regulations

July 23, 2018 by William Michael Carter, The Conversation

12

Like

G+

Tweet

↑

↓

reddit

★

Favorites

✉

Email

🖨

Print

📄

PDF



Will facial recognition software make the world a safer place, as tech firms are claiming, or will it make the marginalized more vulnerable and monitored? Credit: Shutterstock

[after state backing](#)
Nikkei Asian Review

[Year](#)
Forge of Empires - Free Online Game

[with 5% Yield Guarantee x 2 Years](#)
The Reserve - 61 Hideaway

[About This Mini Invention](#)
DroneX Pro

[News > World > Asia](#)



Those with low ratings will face measures such as being banned from taking flights or using trains for up to a year

China blacklists millions of people from booking flights as 'social credit' system introduced

CHINA'S SOCIAL CREDIT SYSTEM

It's been dubbed the most ambitious experiment in digital social control ever undertaken. The Chinese government plans to launch its Social Credit System nationally by 2020.

WHAT'S THE AIM?

The system intends to monitor, rate and regulate the financial, social, moral and, possibly, political behavior of China's citizens - and also the country's companies - via a system of punishments and rewards. The stated aim is to "provide the trustworthy with benefits and discipline the untrustworthy."


The Chinese government considers the system an important tool to steer China's economy and to govern society. There is still much speculation about how the final system will actually function. Details in this chart are based on pilot schemes and plausible expert expectations.

HOW DOES IT WORK?

Each citizen is expected to be given a social credit score that will increase or decrease depending on whether the subject's social behavior is acceptable.


The system is expected to draw on huge amounts of data about each and every individual, gathered from traditional sources - such as financial, criminal and government records and existing data from registry offices or school officials - along with digital sources. The latter include data collected on the Internet, such as the subject's search history, shopping preferences on e-commerce sites and interactions on social media.

Moreover, the system could also rely on information obtained through video surveillance systems with help from facial recognition technology.



China's tight grip on enterprises


Influencing business decisions via Social Credit Scores*



*Selection of data collected and exemplary effects of Social Credit Scores.

Source: Policy documents and regulations released by the Chinese central government since 2014.

Data flows within China's Social Credit System for enterprises



Top 10 data providers for China's National Credit Information Sharing Platform (number of datasets)



Source: NDRC 2016

WORLD

Hong Kong courts set to start going paperless this year

PUBLISHED : 29 APR 2019 AT 18:18

WRITER: SOUTH CHINA MORNING POST

0



1





การใช้ E – Court สนับสนุนการประชุมคดี และการพิจารณาพิพากษาคดีโดยองค์คณะ¹


นายรังสรรค์ วิจิตรไกรสร²

นายบุญเชตร ทุมทิพย์³

¹ บทความนี้สรุปจากการประชุมเชิงปฏิบัติการ เรื่อง “การใช้ E – Court สนับสนุนการประชุมคดีและการพิจารณาพิพากษาคดีโดยองค์คณะ” ระหว่างวันที่ 7 - 9 มิถุนายน 2561 ณ โรงแรม ดี เอลลิเมนต์ กระบี่ รีสอร์ท จังหวัดกระบี่

² ผู้พิพากษาศาลฎีกา, กรรมการเทคโนโลยีสำนักงานศาลยุติธรรม, น.บ. มหาวิทยาลัยธรรมศาสตร์, น.บ.ท. สำนักอบรมศึกษากฎหมายแห่งเนติบัณฑิตยสภา

³ ผู้พิพากษาหัวหน้าคณะในศาลอุทธรณ์คดีชั้นอุทธรณ์พิเศษ, น.บ. มหาวิทยาลัยธรรมศาสตร์, น.บ.ท. สำนักอบรมศึกษากฎหมายแห่งเนติบัณฑิตยสภา, MCL University of Miami, LLM Southern Methodist University



A word cloud featuring the phrase "Thank You" in numerous languages. The words are arranged in a circular pattern, with "THANK YOU" being the largest and most central. Other languages include Spanish (Gracias, Arigato), Arabic (Shukria, Biyan), Hindi (Dhanyabad, Shukriya), and many others. The words are in different sizes and orientations, creating a dynamic and colorful composition.