



“AI 詐騙”沖上熱搜第一,AI 安全或再成焦點

海內外積極因對 AI 風險

5月19日消息，英國計劃與OpenAI和DeepMind的高管舉行關於AI風險的會議，英國的人工智能峰會最快可能在本月舉行。

5月18日，科學技術部長王志剛表示，中國積極應對人工智能可能帶來的風險挑戰，推進人工智能倫理治理，髮佈人工智能治理原則和倫理規範，向全球表明負責任人工智能的鮮明立場。

5月16日，OpenAI CEO Altman呼籲國會對人工智能(AI)系統採取安全標準。他認為，政府可以將發放牌照和測試的要求結合起來，監管開發AI模型的公司。

4月11日，據《華爾街日報》報道，拜登政府已經開始研究是否需要對ChatGPT等人工智能工具實行檢查。作為潛在監管的第一步，美國商務部4月11日就相關問責措施正式公開徵求意見，包括新人工智能模型在發佈前是否應經過認證程序。徵求意見期限為60天。

4月11日，國家互聯網信息辦公室發佈《生成式人工智能服務管理辦法(徵求意見稿)》，向社會公開徵求意見。該意見稿聚焦生成式人工智能，在算法設計、訓練數據選擇、模型生成和優化、提供服務、生成內容、個人信息和隱私保護方面均做出了限制。

據中信證券研報，AI可能引發的安全問題主要體現在以下方面：

1)大模型訓練、調優所使用數據的安全問題。

比如前文所述意大利個人數據保護局因年齡審核、數據和隱私安全等問題，宣佈限制ChatGPT運營；加拿大聯邦隱私監管機構宣佈，OpenAI涉嫌“未經同意收集、使用和披露個人信息”。

2)大模型生成內容的可靠性、使用方式等問題。

中信證券指出，由於大模型在生成內容上的基于概率統計的原理，其內容可靠性可能存在問題，如引用的客觀數據是否是最新且來源可靠的，此外，由AI生成的新聞圖片出現在互聯網中，真假難辨，或引發傳播風險；歐洲刑警組織提示稱，ChatGPT可能被濫用於網絡釣魚、虛假信息和網絡犯罪。

華創證券還提到，網絡攻擊方面，搭載了AI能力的黑客如虎添翼，ChatGPT的強大功能降低了網絡攻擊者用于製作惡意軟件和降低技術門檻，使得攻擊手法轉向分布式、智能化、自動化，智能化對抗將成為主要的攻防形式。

哪些技術有望用來應對AI風險？

中信證券指出，由於大模型在訓練、調優數據過程中涉及用戶數據調用，伴隨生成式AI技術熱潮掀起，在數據採集、傳輸、存儲、處理、共享、銷毀等數據生命周期各階段，通過加密、數據水印等技術手段保護用戶數據特別是隱私成為當務之急。

針對大模型生成內容的可靠性、使用方式，中信認為，應對AI生成內容進行標記，同時對AI

生成內容的可靠性及傳播鏈路進行把關。

安信證券提到，當前對AI生成內容的判別主要可以由兩種技術途徑來完成：

1)通過算法識別AI模型生成內容的特徵，從而鑑別相應的內容是否由AI生成。根據公司公告披露，美亞柏科正在佈局相關取證技術，比如對人工智能合成、生成的視頻圖像內容檢測鑑定。

2)通過對AI生成的內容添加特定的標識，來區分相應內容是否由AI生成，這一方向的技術手段包括數字水印等相應的加密技術。

國盛證券指出，AIGC可能生成的虛假信息，需要類似換臉甄別的技術來鑑別圖像等信息是否由AI生成；數據隱私方面，隱私計算可以在不暴露數據的情況下進行計算和分析，以實現數據隱私的保護。

隱私計算是在保障數據隱私安全的同時，實現數據分析計算的技術體系，其價值是打破數據孤島，實現數據的可信流通和價值挖掘。國泰君安稱，隱私計算在政策和需求的雙輪驅動下不斷發展壯大，到2025年，中國隱私計算市場規模有望突破百億級，市場空間巨大。

國盛證券還提到，安全問題不能僅靠AI廠商自律解決，還需要外部力量監督。全球AI監管處於探索階段，歐盟、英國、美國相關法律法規與指導意見逐步推進。人工智能趨勢不可逆轉，與科學技術的高速發展相比，現有法律和倫理仍處於不斷起步探索的階段。

AI 詐騙屢見不鮮 人工智能如何執好這把“雙刃劍”

一下AI詐騙的幾種主要方式，以此提高警惕

1)利用聲音合成進行詐騙

即通過騷擾電話錄音等來提取某人聲音，獲取素材後進行聲音合成，從而可以用偽造的聲音騙過對方。

2)利用AI換臉進行詐騙

人臉效果更易取得對方信任，通過分析公眾發佈在網上的面部信息，並利用AI換臉技術，在視頻通話中偽裝成想成為的人，並通過視頻電話的方式進行信息確認，獲取信任進行詐騙。

3)利用轉發微信語音進行詐騙

在盜取微信號後，便向其好友“借錢”，為取得對方的信任，通過轉發之前的語音，進而騙取錢款。當前微信沒有語音轉發功能，但不法分子通過提取語音文件或安裝非官方版本(插件)，實現語音轉發。

通過以上案例及AI詐騙方式可以看出，AI日趨廣泛的應用會引發一些社會問題。為了讓AI科技更好的造福人類，我國不斷完善相關法律政策。

2019年2月，科技部在北京召開新一代人工智能發展規劃暨重大科技項目啟動會，成立了新一代人工智能治理專業委員會。6月，國家新一代人工智能治理專業委員會發佈了《新一代

人工智能治理原則》。9月，專委會正式發佈《新一代人工智能倫理規範》。

2021年發佈的《倫理規範》中提出了更加細化與嚴謹的6項基本倫理要求。

2022年3月，中共中央辦公廳、國務院辦公廳印發了《關於加強科技倫理治理的意見》(以下簡稱《意見》)，明確指出科技倫理是開展科學研究、技術開發等科技活動需要遵循的價值理念和行為規範，是促進科技事業健康發展的重要保障。

科技是把雙刃劍。未來，人工智能應如何約束

1)各方積極發力開發音視頻造假檢測技術

目前，聯合國區域間犯罪與司法研究所、美國賽門鐵克等公司研究檢測虛假音視頻技術。臉書與微軟及麻省理工大學合作，發起了“假視頻檢測挑戰”活動，旨在利用人工智能技術更好地甄別深度偽造和合成內容，開發對抗深度偽造技術濫用的方法和工具。我國互聯網企業和研究機構等也積極開展對換臉換聲、合成語音詐騙等技術的研究和檢測。

2)針對人工智能倫理的高風險場景特別立法

應按照針對不同風險等級制定不同嚴苛程度的管理思路，可以通過分場景監管，做到有收有放，不僅降低人工智能倫理執法的難度，而且

推動實現治理與發展的平衡。

3)提陞科研機構和企業對人工智能倫理的認知及自律

在規避人工智能可能產生的倫理風險上，科研機構和企業更容易在相關實踐中獲得第一手信息，也更應該承擔起構建安全人工智能技術的主要責任。

4)提高全社會科技倫理意識

倫理問題涉及到社會行為準則與規範，而治理倫理問題則需從公共管理的角度出發，在充分瞭解人工智能技術所帶來的潛在社會影響，找到相對應的解決辦法，並形成社會對人工智能倫理的共識。建議利用各種渠道廣泛的進行科技倫理宣傳、活動與交流，提陞公眾的科技倫理意識，進而加強全社會對人工智能倫理的廣泛監督。

結語：科技是把雙刃劍，我們在享受科技帶來福利的同時，也在接受考驗。人工智能時代，有人利用AI技術思考的是如何推動人類社會進步，而有的人卻利用AI做違法犯罪之事。我們能做的就是加強自身道德修養，守好道德法律底線，積極推動AI技術發展不斷為人類謀科技福利，堅決反對利用AI技術做違法犯罪之事，同時加強防範意識，做好防範措施，防患于未然，不給不法分子可乘之機。

10分鐘騙走430萬，如何堤防詐騙新技術？

01AI騙子，防不勝防

AI進化的速度有多快，騙術也跟着變得更狠。

福州一位科技公司的老闆，某天突然接到了個好友的微信視頻，說是自己的朋友在外地競標，需要430萬的保證金，想走他的公司賬戶過個賬。老郭在確認視頻通話里的人和聲音都是他朋友之後，就同意了。

隨後，對方就給老郭發了一張銀行卡轉賬成功的截圖，說是錢已經轉到老郭的戶頭上了，由於老郭之前已經確認了朋友的身份，在沒確認錢到帳與否的情況下，直接就把430萬轉到了好友給的銀行卡上。

結果，這是一場騙局，還是AI操控的。雖然接到報警後，福州、包頭兩地警銀迅速啓動止付機制，成功止付攔截336.84萬元，但仍有93.16萬元被轉移。

還有利用AI進行聲音合成實施的詐騙。騙子通過騷擾電話錄音等來提取某人聲音，獲取素材後進行聲音合成，從而可以用偽造的聲音騙過對方。

已經有人因為AI聲音被騙了。曾有某公司財務接到領導電話，要求立刻給供應商轉款2萬元，並將轉賬信息以郵件形式發送，轉款理由是避免繳納滯納金，因為老闆的口音十分逼真，財務也信了，在1小時內轉款完成，轉完才發現被騙。

AI換臉早已不是什么新鮮事，很多短視頻鬼畜博主都精通這種操作，但擬聲技術相對複雜一些，畢竟犯罪分子需要獲取你的聲音，然後通過軟件將聲音變成他們想要的內容。

實際上，如今的騙子想要獲取聲音也並不難，最普遍的方法就是騷擾電話，只要你接電話後並說了幾句話，那麼犯罪分子就會對你的聲音進行錄制，並提取你聲音的信息。

有業內人士表示，犯罪分子通過這一套流程進行詐騙的成功率基本是100%，尤其是面向那些並不懂AI、防範意識可能薄弱的老年群體，AI詐騙更容易發生。

類似的聲音騙局，國外也早有發生。

一個國外的詐騙公司，使用AI模擬了“卷福”的音頻，打電話給一家新西班牙的小電影公

司，稱想要和對方合作，並要求對方先打款20萬英鎊才能見面，結果在電影公司付完錢之後，他們才發現這次事件，完完全全就是一場AI騙局。

對於AI騙局，有律師表示，使用人工智能技術手段模仿真人面容、聲音，冒充親友、熟人、領導等，很容易達到以假亂真的程度，具有極強的迷惑性。與其他類型電信詐騙相比，AI詐騙迷惑性更強，針對性更強，辨識更困難。

如今，耳聽，眼見都不一定為實，各種騙局真是讓人防不勝防。



02 AI有多強大？讓孫燕姿本人都害怕

最近，關於AI還發生了一個熱點：孫燕姿本人親自回應AI孫燕姿。

對於熱門歌手AI，孫燕姿自己都承認，“諷刺的是，人類再怎麼快也無法超越它。”

她在回應小作文里寫道，“人類無法超越AI技術已指日可待。凡事皆有可能，凡事皆無所謂。”就算暫時能夠辨認出AI歌手和真人歌手的區別，很快這條護城河也將不復存在。這種被虛擬淹沒真實的感受，如今已經在全世界蔓延。

AI不光是唱歌可以完全貼近真人，連直播帶貨的活都可以接。

最近有人在直播間里發現，正在賣貨的竟然是當紅女星。然而再定睛一看，這些明星居然是使用了AI實時換臉技術的普通主播。

AI實時換臉，正在直播間悄然出現，楊冪、迪麗熱巴、angelababy等當紅女星，成為了AI換臉的熱門。雖然目前還沒有曝出被騙新聞，但由於明星臉的帶貨主播往往擁有更好的引流效

果，消費者或明星粉絲很可能會衝着明星效應進行消費而被坑騙。

而這種技術門檻也並不高。有媒體報道，AI實時換臉全套模型購買價僅需3.5萬元。

買不起全套模型，還有“AI換臉特效插件”，供買家選擇，售價數百元，只對電腦配置有一定要求，購買後使用者只需更換素材照片，軟件就能自己運行完成“換臉”。這款軟件不僅能對圖片進行換臉，也能在視頻上進行換臉。

AI換臉的風靡，還帶來了“AI脫衣”的新問題。早在今年3月，一則“女子地鐵照被AI一鍵脫衣傳播”的新聞衝上了熱搜，一名女性搭乘地鐵時的一張照片被人用AI軟件“一鍵脫衣”，遭到惡意傳播，罪犯還廣泛散佈不實信息對該女子進行污衊。

更可怕的是，AI深度偽造(DeepFake)內容，可以利用互聯網平台在全球範圍內病毒式傳播。比如AI現在居然還能通過發佈假新聞，讓股市抖三抖。

幾天前，多個經過驗證的推特賬戶，齊刷刷分享了一張聲稱在五角大樓附近發生爆炸的假照片，頓時引起轟動，並導致股市短暫下跌。

這張照片雖然具有AI生成的所有特徵，但是因為被許多經過驗證並打上了藍色勾的推特賬戶分享，不少人還是信以為真，謠言一傳十，十傳百，甚至有人聲稱這張照片與彭博新聞有關。

連印度一家電視台都信了，共和國電視台(Religious TV)報道稱五角大樓發生了爆炸，並在節目中播放了這張假圖片。後來，當發現美國當地官員證實沒有發生此類事件後，共和國電視台快速撤回了這則報道，這一番操作下來也是相當尷尬。

03 AI騙局，並非沒有破綻

隨着AI技術的不斷發展，被AI騙的人越來越多。根據殺毒軟件McAfee公佈的最新報告，基於人工智能的語音詐騙越發猖獗，在接到AI詐騙電話的群體中，有77%的人會上當受騙。

今年3月，一份名為《暫停大型人工智能研究》的公開信在未來生命研究所官網上發佈，包括特斯拉CEO埃隆·馬斯克(Elon Musk)、蘋果公司聯合創始人史蒂夫·沃茲尼亞克(Steve

Wozniak)等人在內的千名科學家、企業高管簽字呼籲暫緩GPT-4以上版本的研發，他們矛頭所指都是強大AI技術可能的負面用途。

不過AI詐騙雖然逼真，但它並不是沒有破綻，比如AI換臉技術會導致臉部變形，一些主播低下頭頭頂會發黑，AI的聲音，也很難表達真實的主觀情緒。

正如不少網友所說，AI孫燕姿“根本不是孫燕姿的唱法。”“AI孫燕姿能模仿她的音色，但模仿不到她的感情；AI孫燕姿能模仿她的聲音，但模仿不了她的現場。”

與此同時，國內與AI換臉、換聲相關的法律法規也在不斷完善。

在過去，“AI換臉”被大量使用到影視劇二度創作、趣味惡搞視頻、表情包製作當中，其中隱藏的法律風險和侵權糾紛，如今都在得到重視，不少擦邊行為已經得到了及時的懲治。

比如近期，據企查查官網信息顯示，上海魚腥草信息科技有限公司就因旗下一款換臉手機APP遭多位網紅博主起訴，很快在監管部門約談後，這款App下架，因為換臉侵犯了公民的肖像權。

去年12月，《互聯網信息服務深度合成管理規定》發佈，對人臉生成、替換、操控，合成人聲、仿聲等都有明確約束。顯然，隨着制度設計更精準，相關立法更健全，AI肆意換臉的空間將越來越小。

就在4月11日，國家互聯網信息辦公室又迅速起草了《生成式人工智能服務管理辦法(徵求意見稿)》，涉及的生成式人工智能包括基於算法、模型、規則生成文本、圖片、聲音、視頻、代碼等內容的技術，可以說，對當下的AI偽造都進行了更為全面的約束。

