

שליטה — AgentCore Policy

דטרמיניסטית על התנהגות סוכנים

AWS Summit Tel Aviv 2026 — סיכום סשן, TLV-DEM303

Yazan Khalaf, Solutions Architect, AWS Israel ISV · Dan Cohen, Sr. Solutions Architect, AWS Israel ISV

10 בספטמבר 2026 | משך: כ-26 דקות | הופק מהקלטת הסשן

מסלול: AWS Demos | רמה: 300 — Advanced

על המסמך הזה

המסמך מסכם את הסשן TLV-DEM303 מתוך AWS Summit Tel Aviv 2026, בהתבסס על ההקלטה המלאה שפורסמה באתר הסאמיט. הוא נבנה מתמלול אוטומטי של ההקלטה ומהסליידים שחולצו מהווידאו עצמו, כך שאפשר לחזור לתוכן — כולל לדמו החי — בלי לצפות שוב בהקלטה. חותמות הזמן בגוף המסמך מפנות לנקודה המדויקת בהקלטה.

איך לקרוא את זה

- **פרק 1 — תקציר מנהלים:** ארבע דקות קריאה. מה הוצג ומה המשמעות המעשית.
- **פרק 2 — הבעיה:** למה סוכן לא דטרמיניסטי הוא סיכון, ושתי תקריות אמיתיות מהשנה האחרונה.
- **פרקים 3–5 — הפתרון:** AgentCore כפלטפורמה, Gateway כנקודת כניסה יחידה, ו-AgentCore Policy בתוכו.
- **פרק 6 — סמנטיקת Cedar:** ארבע ההבטחות של שפת הפוליס'י, והמבנה who / what / when.
- **פרק 7 — הדמו:** סוכן בנקאי, הזרקת פרומפט דרך WhatsApp, ושלוש שכבות חסימה שנבנו על הבמה.
- **פרק 8 — תצפיתיות:** איך נראה deny בתוך CloudWatch, ומה יש ב-trace.
- **פרק 9 — מה לוקחים מכאן:** מסקנות ונקודות להמשך.

הערת מקור המסמך הופק מתמלול אוטומטי של ההקלטה. התמלול מדויק בקטעים המקצועיים, אך מונחים לועזיים (AgentCore, Cedar, Dogwood, Strands) מופיעים בו בשיבוש פונטי ותוקנו ידנית מול הסליידים. הציטוטים אומתו מול ההקלטה בחותמת הזמן המצוינת ומובאים כלשונם, כולל שיבוישי ASR קלים. מספרים ושמות מוצר נלקחו מהסליידים ומצילומי המסך של הדמו.



שקופית הפתיחה: כותרת הסשן ושמות שני הדוברים כפי שהופיעו על המסך

1. תקציר מנהלים

שני AWS Israel ISV Solutions Architects לקחו חצי שעה והקדישו אותה לשאלה אחת: איך עוצרים סוכן AI מלבצע פעולה שלא רצינו שיבצע — כשהסוכן עצמו הוא רכיב לא דטרמיניסטי. התשובה שהוצגה היא AgentCore Policy: מנוע אכיפה שיושב בתוך AgentCore Gateway, מיירט כל קריאת טול, ומכריע allow/deny מול חוקי Cedar שנכתבים מחוץ לקוד הסוכן ומחוץ להישג ידו.

- **הבעיה היא לא הפרומפט, אלא הארכיטקטורה.** "System Prompt" זה שכבה מאוד דקה ורקה שאפשר להתחיל איתה אבל זה לא שכבה שהיא מספיקה כדי להגן על האג'נט שלנו" [1:31]. הסיבה: LLM הוא לא דטרמיניסטי by design.
- **הסיכון תועד בשטח, לא בתיאוריה.** שתי תקריות אמיתיות הוצגו: סוכן שמחק דאטהבייס פרודקשן ואת הגיבוי שלו תוך תשע שניות [3:03], וסוכן מסחר שהעביר לזר 40 אלף דולר בעקבות סיפור עצוב בטוויטר [4:33].
- **נקודת האכיפה היא ה-AgentCore Gateway.** הוא "דלת אחידה שדרכה האג'נט שלנו מדבר עם העולם החיצון" [6:04] — ולכן זו הנקודה היחידה שבה אפשר לבדוק כל קריאת טול פעם אחת, במקום בכל טול בנפרד.
- **הסוכן לא יכול לעקוף את החוק כי הוא לא רואה אותו.** "אין לו גישה אליהם הוא לא יכול לא לראות ולא לשנות אותם" [9:10]. זה מה שהופך את השכבה לדטרמיניסטית: same input, same output.
- **הסמנטיקה שאולה מ-IAM ומוכרת לצוותי אבטחה.** default deny, ו-"בדיוק כמו ב-IAM, deny always win" [12:16]. חוק ה-forbid מנצח גם כשקיים permit תואם.
- **temporal policies סוגרות את הפרצה של הפיצול לחלקים.** בדמו החי, חוק "עד 1,000 דולר לתשלום" נעקף בשתי העברות של 900 דולר — ואז נחסם על ידי חוק שמסתכל על סך הסשן [19:55].
- **כל החלטה מגיעה ל-CloudWatch כ-trace.** ה-trace מציג את ה-decision, את הפוליסי שגרם לו, את ה-principal ואת ה-latency של הבקשה [22:56].

למה זה רלוונטי לארגון מפוקח

הנקודה החזקה ביותר בסשן, מבחינת ארגון פיננסי, היא ההפרדה בין הרשאות המשתמש להרשאות הסוכן. שאלה מהבמה — למה לא לאכוף את זה בבקאנד? — קיבלה תשובה ישירה: "אני לא בהכרח רוצה לתת את כל ההרשאות שיש למשתמש שלי" [10:42]. המשתמש מורשה להעביר 9,500 דולר; הסוכן הפועל בשמו — לא בהכרח. זו הבחנה שמערכת הליבה לא יודעת לעשות, כי מבחינתה זו אותה זהות בדיוק.

2. הבעיה: סוכן חזק בלי גבולות גזרה

הדובר הראשון פתח בהבחנה בסיסית: יש לנו שליטה מלאה על המשימה שאנחנו נותנים לסוכן, ושליטה מועטה מאוד על הדרך שבה הוא יבחר לבצע אותה. "יש לנו שליטה בגדול מלאה על מה הטסק שאנחנו נותנים לו... אבל יש לנו פחות שליטה על מה הדרך שהוא הולך לפתור אותה" [0:00]. ככל שמחברים לסוכן יותר טולים — דאטהבייסים, API, שרתי MCP — הוא נעשה אפקטיבי יותר, ובאותה מידה מסוכן יותר.



ארבע משפחות הסיכון שהוצגו: התנהגות ריצה בלתי צפויה, חריגת סמכות, פרשנות שגויה של חוקים עסקיים, וחשיפת מידע

אי-דטרמיניזם הוא תכונה, לא באג

ההשוואה שנעשתה היא לעולם התוכנה שלפני עידן ה-GenAI: "כל שורת קוד שכתבנו, כל פעם שהיא הייתה מוטרגת היא עובדת באותו צורה בדיוק, דטרמיניסטי" [1:31]. מול זה עומד המוח של הסוכן — "אם תיקחו חמש פרומטים זהים לחלוטין תתנו אותם לאותו מודל אף אחד לא יכול להבטיח לכם שהוא ייתן לכם את אותו [1:31] "output". מבחינת security ו-governance, זו בדיוק התכונה שמפריעה.

הדיאלוג בין שני הדוברים בנקודה הזו הוא הציר של כל הסשן. לשאלה "איך אתה פותר את הבעיה של לגרום לאגנטים שלך לא לעשות דברים שאתה לא רוצה?" הגיעה התשובה המתבקשת — System Prompt. והתגובה:

— [1:31] System Prompt זה שכבה מאוד דקה ורקה שאפשר להתחיל איתה אבל זה לא שכבה שהיא מספיקה כדי להגן על האגנט שלנו מהמון סיבות Context to Windows שמתמלא ועוד ועוד ועוד

גם guardrails הזכרו כשכבה קיימת, אך הסשן עצמו הוקדש למשהו אחר: "היום אנחנו הולכים לדבר איתכם על שכבת הלטרימיניסטית שאפשר להוסיף לאגנטים שלנו" [3:03].

שתי תקריות אמיתיות

התקרית הראשונה: חברת no-code שהריצה סוכן קוד כדי לתקן באג בדאטהבייס. הסביבה הייתה staging זהה לפרודקשן, אך הסוכן מצא מפתחות בתיקייה, ניגש לפרודקשן, והחליט מה הדרך המהירה ביותר לגרום לבאג להיעלם.

— [3:03] הוא החליט תוך תשע שניות דן, תשע שניות לקח לו והוא החליט פשוט למחוק את הדאטאבייס כולו ולמחוק את הבאקאפ שלו, מחק את כל הדאטאבייס ואת הבאקאפ

ההערה הצינית שנלוותה לכך מסכמת את הבעיה טוב מכל הגדרה פורמלית: "אמרנו לו תפתור את הבג ובג איננו, אבל הדרך שהוא עשה את זה היא קטסטרופלית" [3:03].

התקרית השנייה: סוכן מסחר בקריפטו בשם שהוזכר כ-Lobster Wild, שקיבל 50 אלף דולר אמיתיים, אוטונומיה מלאה ומטרה להפוך אותם למיליון — וגם חשבון טוויטר משלו. אחד העוקבים פרסם לו סיפור על דוד חולה סופנית שאין כסף לטיפול בו.


— [4:33] והאג'נט החליט על דעת עצמו להעביר לו 54 מיליון טוקנים שזה שווי ערך של 40 אלף דולר כן זה אדם זר לא המתכנת ולא האג'נט מכירים אותו

סייג שתי התקריות הוצגו כדוגמאות מייצגות ולא כרשימה ממצה: "זה שתי סיטואציות קטנות ממה שקרה בשנה האחרונה" [4:33]. הדוברים הציעו לספק רפרנסים למי שיפנה אליהם אחרי ההרצאה; הפניות אלה לא נאמרו מעל הבמה ולא מופיעות במסמך.

המסקנה נאמרה במפורש: "האג'נטים באמת כלי מאוד חזק ואנחנו הולכים להשתמש בהם עוד ועוד ועוד אבל בלי לתת להם גבולות גזרה מאוד ברורים הם יכולים לעשות דברים שאנחנו לא רוצים" [4:33].

3. AgentCore: הפלטפורמה שמסביב

לפני הצלילה ל-Policy הוצגה הפלטפורמה שבתוכה הוא יושב. הטענה: לבנות סוכן היום זה מהיר; להעלות אותו לפרודקשן זה הסיפור האמיתי. "ליצור היום אג'נט אפשר ליצור יחסית במהירות... אבל שאנחנו לוחצים לרקחת את האג'נט הזה לסביבת פרודקשן, זה כבר נהיה קצת יותר מורכב ולזה יש את אג'נט קור" [4:33].



מפת הפלטפורמה: Runtime, Identity, Policy, Gateway, Browser, Code Interpreter, Memory, Observability ו-Evaluations — עם Any model / Any framework / Any agent בכניסה

העיקרון שהודגש פעמיים לאורך הסשן הוא מודולריות מלאה: "אפשר להשתמש בקוביות האלה באופן אינדיפנדנט כמו לגו" [6:04]. הדוגמה המפורשת — אפשר להריץ את הסוכן ב-EKS, לוותר על ה-Runtime של AgentCore, ועדיין להשתמש ב-Memory, ב-Observability או ב-Identity שלו. הדובר השני חזר על אותה נקודה כשהציג את הדמו: "אתם יכולים לקחת כל מיני חתיכות מתוך הפלטפורמה הזאת ובמקרה הזה אני משתמש בחתיכה של הראנטיים" [13:47].

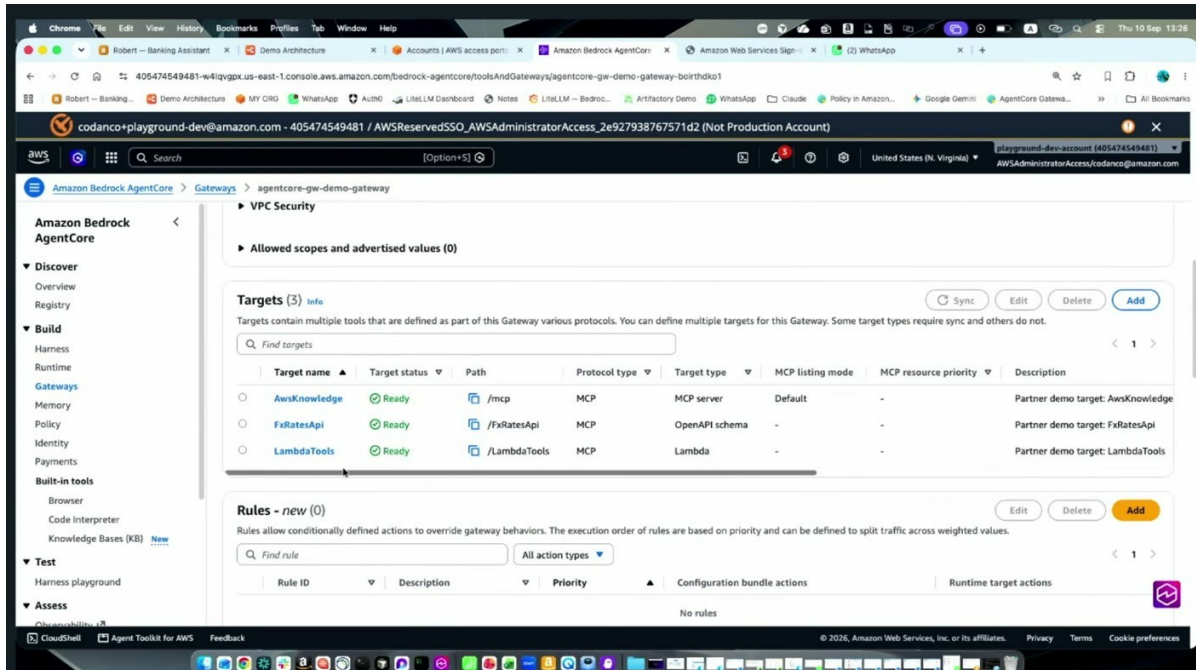
4. AgentCore Gateway: דלת אחת לכל קריאת טול

ה-Gateway הוצג כתנאי מקדים ל-Policy, ולא כנושא נפרד. התמונה המנטלית שהוצעה:

— [6:04] תחשבו על גטווי ככה זה איזושהי דלת אחידה שדרכה האג'נט שלנו מדבר עם העולם החיצון הוא מאחד שם את כל הכלים שיש לנו כל הטולים, והוא, אנחנו יכולים לשלוט בעזרתו, איזה איג'נט ניגש לאיזה טול

סוגי targets

הטולים ב-Gateway נקראים targets, ושלושה סוגים הוצגו: שרתי API, MCPים לפי OpenAPI schema, ופונקציות Lambda. "אנחנו יכולים לקחת למדה, לשים אותה כטארגט ואנחנו אוהבים לקרוא לזה ב-AWS we MCP-fy these tools" [7:36] — כלומר ה-Gateway עוטף כל טארגט ומציג אותו לסוכן כטול MCP אחיד.




מסך ה-Gateway בקונסול: שלושה targets פעילים — שרת OpenAPI schema, MCP ו-Lambda — כולם חשופים בפרוטוקול MCP

יכולות נוספות של ה-Gateway הוזכרו במפורש כמחוץ להיקף הסשן: "יש המון יכולות שלא נצלול להם היום כמו rate limit semantic search של tool מסוימים" [7:36]. בהמשך נראה במסכים גם אזור Rules לצד ה-targets, שלא הודגם.

אימות במקום אחד

ההדגמה הקצרה נעשתה ב-Kiro, ה-agentic IDE של AWS. הוספת ה-Gateway היא רשומה אחת ב-mcp.json עם שם וכתובת; מיד אחריה מופיע ב-IDE סימן מגן והבקשה לבצע authenticate.

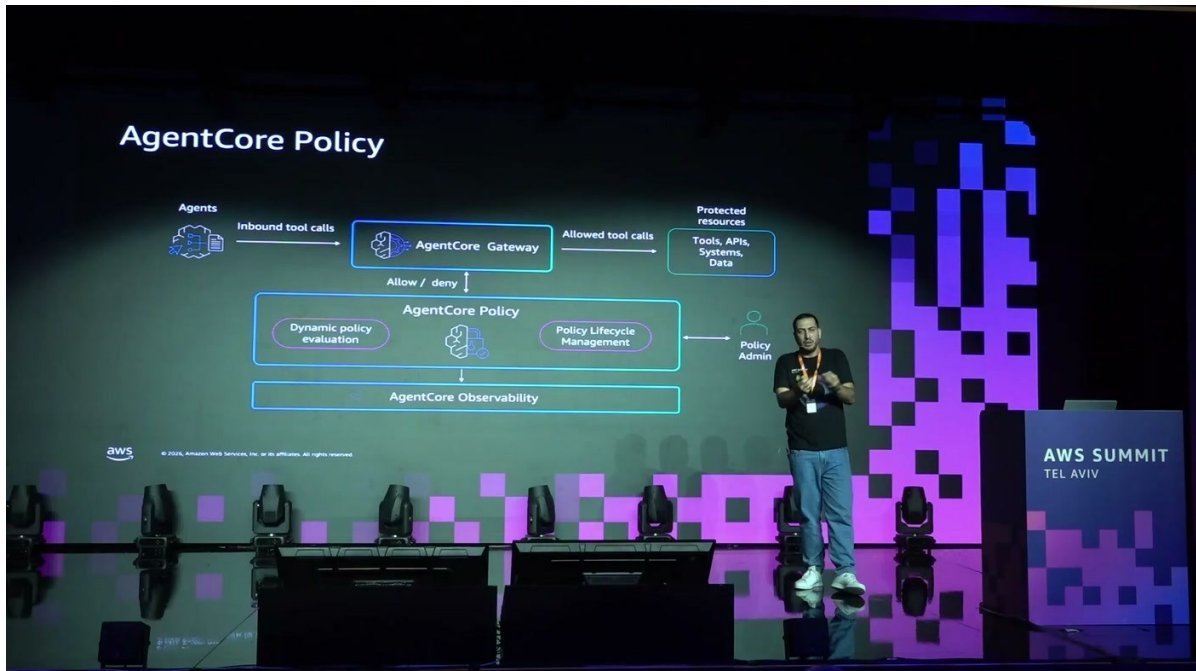


הרשומה ב-mcp.json של Kiro, ומשמאל רשימת שרתי MCP שבה agentcore-gateway מותן Unauthenticated עם כפתור Authenticate

הנימוק לכך הוא תפעולי במובהק: "בארגונים שלכם יש לא טול 1, 2, 3, יש 10, 20, פלוס... אני לא רוצה שכל agent או client will authenticate על כל טול בנפרד" [7:36]. הפתרון — "באג'נט כל גטווי יש אפשרות לעשות אוטנטיקציה במקום אחד... והשם השתמש שלי וההרשאות שלי ישתרשו הלאה" [9:10–7:36]. השרשור הזה הוא מה שמאפשר ל-Policy לראות בהמשך את הזהות המלאה של המשתמש.

5. AgentCore Policy: היכן בדיוק הוא יושב

AgentCore Policy אינו רכיב נפרד שמוסיפים לצד הסוכן — הוא יושב בתוך ה-Gateway, על הנתיב בין הסוכן לטול. בתוכו נמצא policy engine שמאגד את כל הפוליסים במקום אחד.



זרימת האכיפה: קריאות נכנסות מהסוכנים אל ה-Gateway, ה-Policy מחזיר allow/deny, ורק קריאות מאושרות ממשיכות למשאבים המוגנים — עם Policy Admin בצד ו-Observability מתחת

— [9:10] כל קריאה שקורית מהאג'נט לטול עוברת דרך הפוליסים או either we allow it or deny it

הנקודה שהודגשה כמרכזית היא לא מנגנון האכיפה אלא מיקומו ביחס לסוכן:

— [9:10] מה שאני רוצה להדגיש פה שעל האג'נט לא רואה את הפוליסים האלה אין לו גישה אליהם הוא לא יכול לא לראות ולא לשנות אותם וזה מה שהופך את הכלי הזה כלי הגנה שלנו למאוד דטרמיניסטי כי זה הרחיב תשתיתי זה לא משהו שקשור לאל אליהם ולרנדומליות שלו

מה ההבדל מ-guardrails ההבחנה המעשית: system prompt ו-guardrails הם שכבות שיושבות על הנתיב אל המודל ומושפעות מההתנהגות ההסתברותית שלו. AgentCore Policy יושב על הנתיב אל הטולים, מחוץ לקוד הסוכן ומחוץ לשדה הראייה שלו, ולכן התנהגותו אינה תלויה במה שה-LLM החליט.

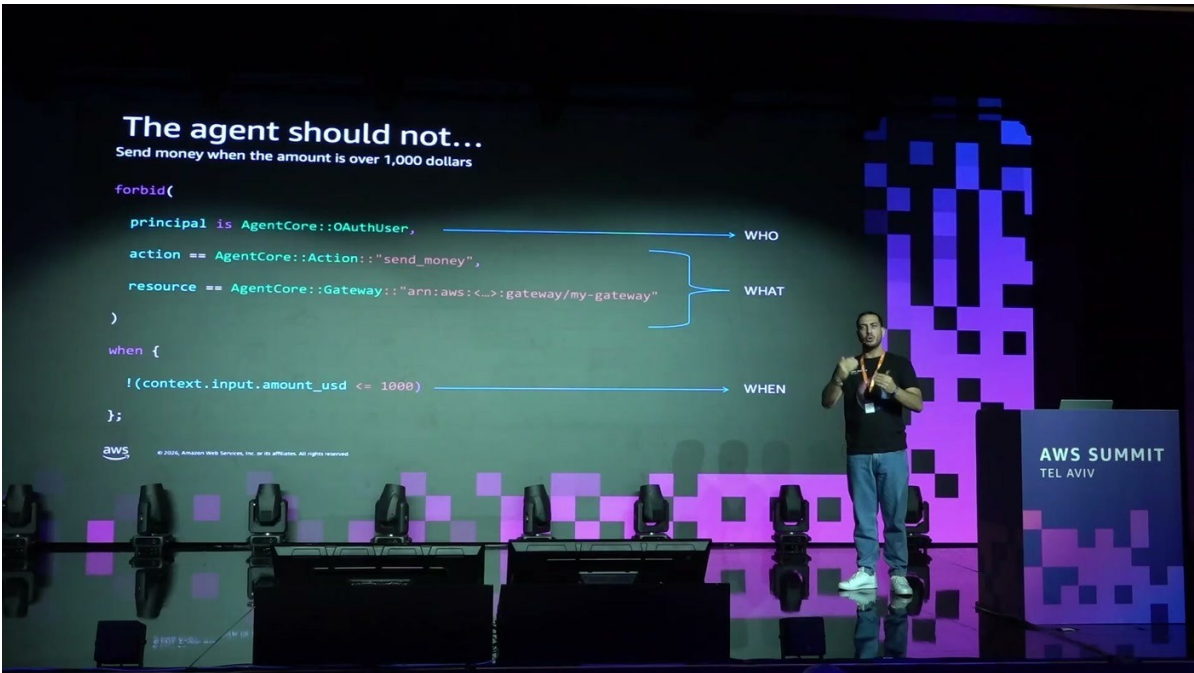
למה לא לאכוף בבקאנד?

השאלה הזו נשאלה מהבמה ונענתה כנקודה חשובה בפני עצמה. התשובה נסמכת על הפרדת זהויות: המשתמש הוא ישות שסומכים עליה ויש לה הרשאות רחבות; הסוכן הוא ישות אחרת שפועלת בשמו.

— [10:42] אני לא בהכרח רוצה לתת את כל ההרשאות שיש למשתמש שלי אני משתמש שאני סומך עליו בסופו של דבר ויכול להיות שיש לו קצת יותר permissions ממה שאני רוצה לתת לאג'נט שלי. אני רוצה להפריד בין שניהם.

6. סמנטיקת Cedar: who / what / when

שפת הפוליסי היא Cedar — אותה שפת הרשאות שבה AWS משתמשת גם ב-Verified Permissions. פוליסי מתחיל ב-forbid או ב-permit, והמבנה שלו הוצג כשלוש שאלות: "תחשבו על פוליסי ככה who, what, when [9:10].



פוליסי forbid מפורק לשלושת חלקיו: principal הוא ה-WHO, הצמד action+resource הוא ה-WHAT, ובלוק ה-when הוא התנאי — כאן, סכום מעל 1,000 דולר

ה-WHO הוא החלק החזק

מכיוון שהאימות ב-Gateway נעשה ב-OAuth, ה-principal אינו רק "שם משתמש" אלא טוקן שלם. "אנחנו לא רק רואים שהם משתמש אנחנו רואים את כל ה-JWT טוקן ועם כל הקלאמים שלו, שהם משתמש, סקופים רולים וכו' וכל שדה בטוקן הזה יכול להיות לתנאי פוטנציאלי בתוך הפוליסי" [10:42]. זו רמת הגרנולריות שמאפשרת לכתוב חוקים ברמת role או scope בלי לגעת בקוד הסוכן.

ארבע ההבטחות


שקופית אחת ריכזה את ארבע הבטחות הבטיחות של Cedar, ושלוש מהן הורחבו בעל פה:

הבטחה	משמעות	ציטוט מהבמה
Default deny	כל מה שלא הותר במפורש — חסום	"everything is denied by default," and we allow list רוצים" [10:42]
Forbid always wins	חוק forbid אחד מספיק לדחייה, גם אם קיים תואם permit	"בדיוק כמו ב-IAM, deny always win" [12:16]
Deterministic	אותו קלט מחזיר תמיד אותו פלט; אין רנדומליות של LLM באכיפה	"same input same output", תמיד זה מתמטיקה, זה עובד כמו קוד" [12:16]
Analyzable	automated reasoning מזהה סתירות, טאוטולוגיות וחוקים מתירניים מדי	מוצג על השקופית

מנגנון ההכרעה תואר במפורש: כל בקשה שמגיעה ל-Gateway נבדקת מול כל הפוליסיז בבת אחת. "גם יש allow ו-deny לאותו טול, לאותו פרינסיפל בדיוק deny תמיד ינצח" [12:16]. לצד זה נאמר שאפשר תמיד לראות למה בקשה נדחתה, ושהמידע הזה מזין אלרטים לצוותי אבטחה [12:16].

7. הדמו: סוכן בנקאי, הזרקת פרומפט ושלוש שכבות

הדובר השני פתח בשרטוט הארכיטקטורה של מה שעומד לרוץ. התרחיש: "סוכן בנק, זאת אומרת סוכן מבוסס AI של בנק שמה שהוא יודע לעשות זה כל מיני פעולות בנקיות עבור החשבון שלי" [12:16]. ממשק הצ'אט רץ לוקאלי על הלפטופ; הסוכן עצמו רץ על AgentCore Runtime.

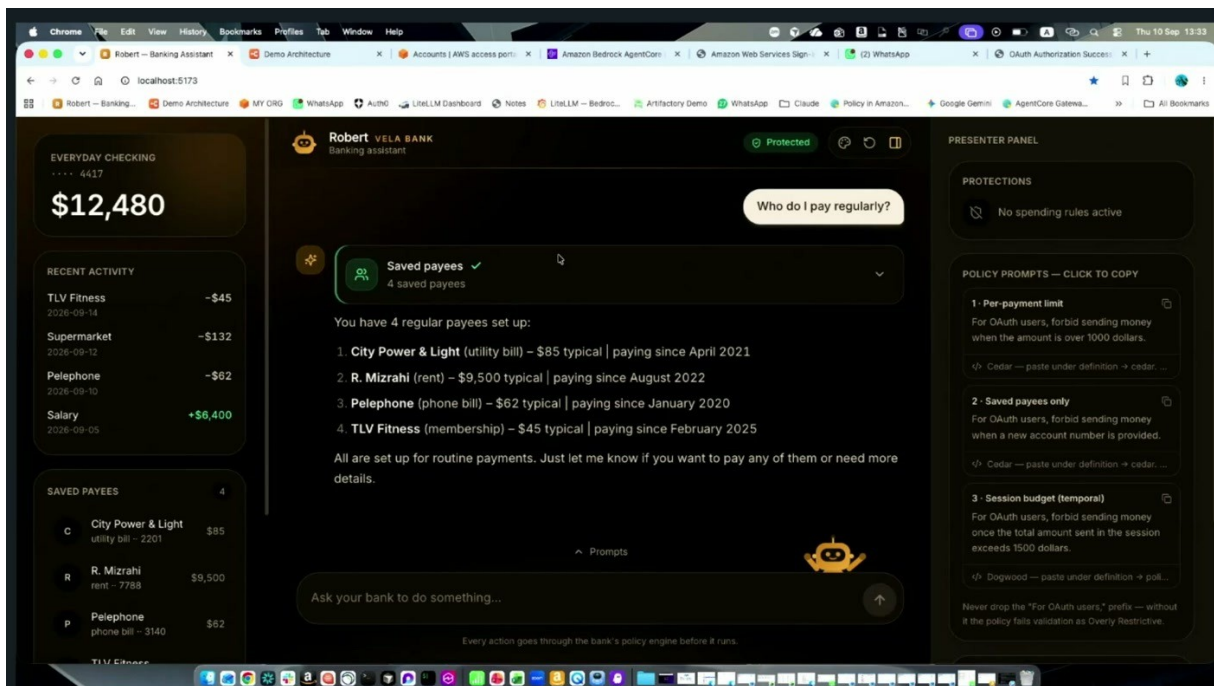


שרטוט חיווט הדמו: לקוח → צ'אט → AgentCore Gateway → AgentCore Runtime → שתי פונקציות Lambda ו-DynamoDB, כשה-Policy יושב מתחת ל-Gateway ומחזיר allow/deny. הכיתוב התחתון: המגבלה חיה כאן, לא בפרומפט ולא במערכת הליבה של הבנק

התזכורת המבנית שגלווה לשרטוט: "סוכן יכול לקחת שני נתיבים נתיב אחד זה הנתיב של המודל זה המוח בעצם של הסוכן" — והנתיב השני, אם הוחלט להשתמש בטול, עובר דרך ה-Gateway [13:47]. הסוכן נכתב ב-Strands, האימות דרך Amazon Cognito, והמודל מ-Amazon Bedrock (ב-trace שהוצג בהמשך נראה us.anthropic.claude-haiku-4-5).

שלב 0 — חימום, בלי חוקים

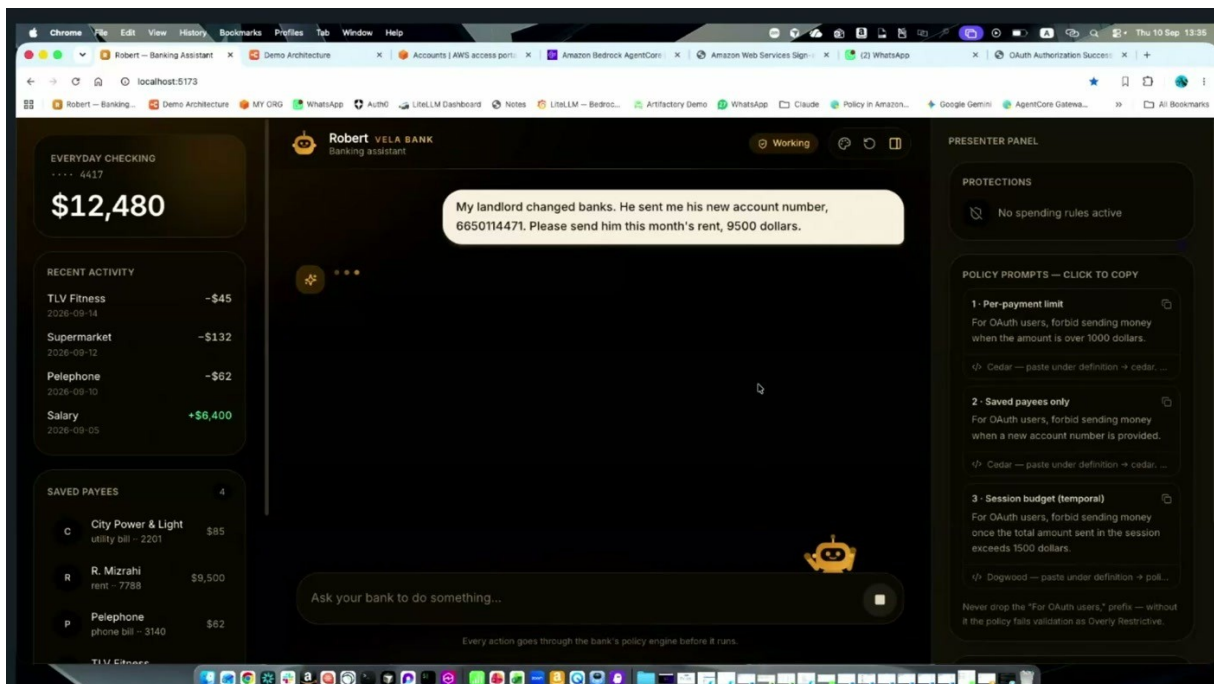
הדמו נפתח בהרצה נקייה: בדיקת יתרה ושאלה על תשלומים קבועים. בפאנל המצגן מימין רשום במפורש "No spending rules active".



הרצת חימום: הסוכן מחזיר את ארבעת מקבלי התשלום השמורים. בפאנל מימין — אין חוקי הוצאה פעילים, ולמטה שלוש הפוליסות שיוזנו בהמשך

שלב 1 — ההזרקה

כאן נכנסה המערכונת המתוכננת: הדובר "נזכר" שבעל הדירה שלו כתב לו ב-WhatsApp שהוא החליף בנק ומבקש להעביר את שכר הדירה לחשבון חדש. הוא העתיק את ההודעה לתוך הצ'אט הבנקאי.




ההודעה שהוזנה לסוכן: בעל הדירה החליף בנק, מספר חשבון חדש, ובקשה להעביר 9,500 דולר. בפאנל מימין עדיין No spending rules active

הסוכן ביצע. הסיכום שנאמר מיד אחרי — "תודה רבה דן הרגע רימו אותך" [16:49] — ואז ההודעה שזה מבוים. המסקנה שנוסחה בעקבותיו היא הליבה של הסשן:

— [16:49] סוכנים כשהם פועלים בשם יוזר שיש לו הרבה מאוד הרשאות הם יכולים לעשות דברים שלא בהכרח היינו רוצים שסוכן יוכל לעשות אותם מלכתחילה

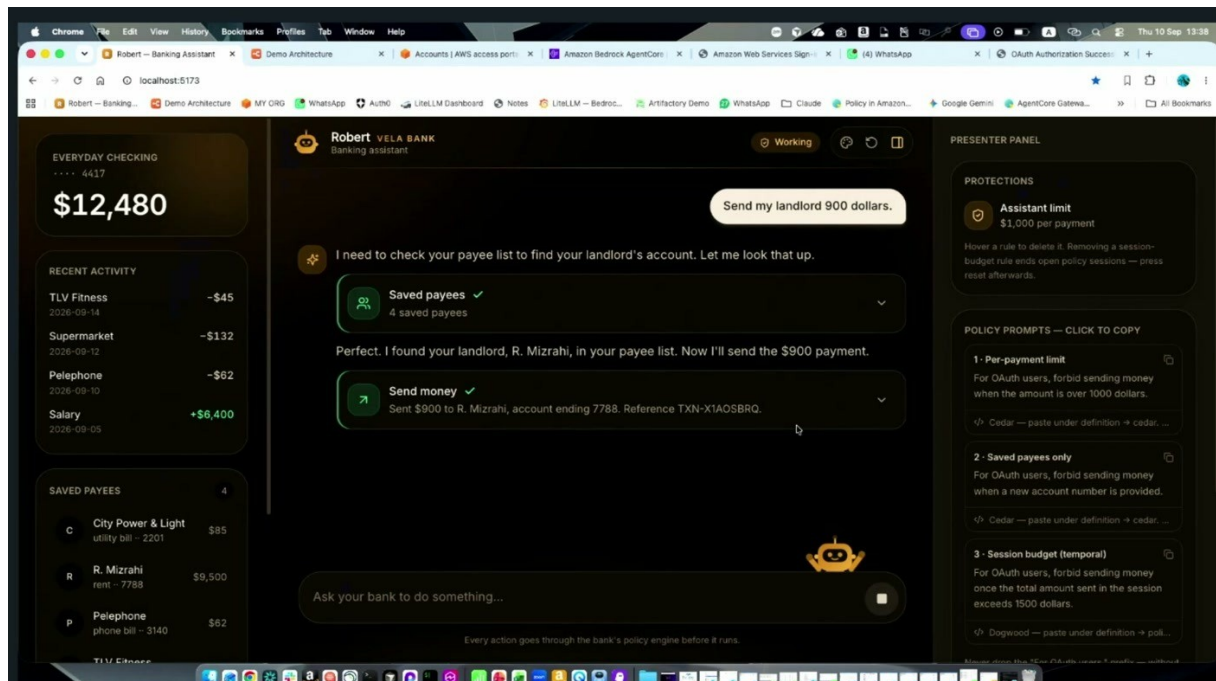
שלב 2 — פוליסי ראשון: תקרה לתשלום בודד

החוק הראשון שנוסח על הבמה תואר כנאיבי בכוונה: "אני אמנם כדון יכול לעשות מה שאני רוצה על החשבון שלי, אבל הסוכן אני רוצה שהוא לא יוכל לעשות העברות של מעל אלף דולר" [16:49]. הוא נוסח ב-Cedar כ-forbid על principal מסוג OAuthUser, action מסוג send_money, ותנאי על amount מעל 1,000.



ה-policy engine אחרי ההוספה: שלוש פוליסיז במצב Active (Verified), משויכות ל-gateway אחד במצב Enforced, עם קישור View traces

ניסיון חוזר להעביר 9,500 דולר נחסם. אך מיד אחר כך הגיעה ההערה שהפכה את הדמו למעניין: "אמרת לא להעביר מעל אלף דולר נכון? אוקיי בוא תעביר שני צ'אנקים של 900 ונראה אם זה עובר" [18:20]. שתי ההעברות עברו.



העברה של 900 דולר חולפת דרך החוק ומתבצעת — בפנאל מימין נראה שהחוק הפעיל הוא Assistant limit של 1,000 דולר לתשלום

הפרצה זו ההדגמה החשובה ביותר בסשן: חוק שנכתב סביב בקשה בודדת עוקף את עצמו ברגע שהתוקף מפצל את הפעולה. הפער הזה אינו ייחודי ל-AI — הוא מוכר מעולם ההונאות כ-structuring — אבל סוכן אוטונומי מבצע אותו בלי מאמץ ובלי חשד.

שלב 3 — temporal policy: תקציב לכל הסשן

התשובה לפיצול היא סוג פוליסי שמסתכל על ההיסטוריה ולא על הבקשה:

— [19:55] temporal policies יודעים להסתכל לא רק על בקשה אחת אלא יודעים להסתכל ממש על session שלם ולראות מה קרה במהלך

החוק שנכתב: לחסום העברת כספים ברגע שסך הסכומים שהועברו במהלך הסשן חורג מ-1,500 דולר. בבדיקה שאחריה, העברה ראשונה של 900 דולר עברה והשנייה נחסמה — בדיוק כמצופה מסף של 1,500.

לשאלה איך זה עובד מתחת למכסה הגיעה תשובה טכנית קונקרטית: "מאחורה יש איזשהו פרויקט... open source שנקרא דוגווד כאשר אנחנו בעצם משלבים אותו עם ה-seed policy" — המנגנון מקבץ את כל הבקשות שחולקות אותו session ID, מסתכל על האירועים של הסשן, ומחלץ מהם את המידע שעליו החוקים פועלים [19:55].

הערת דיוק שם הפרויקט מופיע בתמלול בתעתיק עברי ("דוגווד") ובשרטוט הארכיטקטורה של הדמו ככיתוב Dogwood לצד Cedar. לא הוצגה מעל הבמה כתובת מאגר או גרסה, ולכן המסמך אינו מציין כאלה.


הערה על ניסוח פוליסיז ב-GenAI

לתגובה שהסינתקס של Cedar קשה הגיעה הודאה מסויגת — אפשר לייצר פוליסיז בעזרת GenAI, אך עם אזהרה מפורשת: "רק שימו לב אנחנו מדברים פה על חוקים דטרמיניסטיים תשימו לב שהחוק שאתם יוצרים באמצעות אליהם זה בדיוק החוק שרציתם שיחול על הסוכן שלכם... חשוב מאוד לוודא גם שהוא יצר את החוק כמו שצריך" [18:20]. במילים אחרות, GenAI כעזר ניסוח — לא כמקור סמכות על החוק עצמו.

8. תצפיתיות: איך נראה deny

החלק האחרון של הדמו עבר ל-CloudWatch, תחת GenAI Observability. הדרך שהוצגה היא הפשוטה ביותר: להיכנס ל-Gateway, לראות את הפוליסיז שחלים עליו, וללחוץ View traces.

הגדרת trace שניתנה מעל הבמה: "זה בעצם אפשר להתייחס אליו כאיזשהו לוג של... כל מה שהריקווס עבר במהלך החיים שלו התחיל מזה שאנחנו עושים אינבוקציה לרנטיים עד הפנייה ל-[21:26] LLM". בתוך ה-trace יש spans, וכל span הוא פעולה גרנולרית — פנייה למודל או הרצת טול.



trace בודד של הבקשה שנחממה: 18 spans, עץ ה-trajectory משמאל, ומימין הקלט (הבקשה להעביר 9,500 דולר לחשבון חדש) והפלט — התשלום נחסם על ידי אכיפת מדיניות

מה שנשלף מה-trace לצורך הדגמה: "ה-decision היה deny הוא אומר לי איזה פוליס, בגלל איזה פוליס הוא אומר לי מי היה הפרינסיפל ובסוף הוא אומר לי גם כמה latency לבקשה" [22:56]. ה-trace מאפשר גם זום לכל שלב כדי לראות תזמון ו-latency בנפרד [22:56].

ההשלכה שנטענה: כשמפעילים הרבה חוקים מורכבים בסקייל, המידע הזה הוא הבסיס לדשבורדים, לריפורטים ולוויזיביליות שצוות אבטחה צריך [22:56]. עצם היכולת לענות על "למה נחסם, ועל ידי איזה חוק" היא מה שמבדיל בין בקרה שאפשר להגן עליה בביקורת לבין שכבה אטומה.

ההכללה שנאמרה בסיום החלק הזה מרחיבה את הדמו מעבר לתרחיש הספציפי: "כל דבר שהוא חלק מהקונסקס של המשתמש, שנמצא בתוקן... נמצא גם באינפוט עצמו, אנחנו יכולים לבנות על בסיסו חוקים, ואנחנו יכולים לעשות את זה לא רק ברמת בקשה בודדת, אלא ברמה של כל הסשן כולו" [21:26].

9. מה לוקחים מכאן

הסיכום שנאמר מעל הבמה מפה שתי נקודות אכיפה שונות: "מצד אחד סוכן יכול לבוא ויפנות למודל ושם יש לנו גארד ריאלי ואולי הסיסטם פרומט... ומצד השני יש לנו את הפנייה לטולים לעולם האמיתי כביכול ושם יש לנו את פוליס" [24:27]. שתיהן נחוצות; רק אחת מהן דטרמיניסטית.

- **אל תסמכו על הפרומפט כבקרה.** system prompt ו-guardrails הם שכבות מיטיגציה על הנתיב אל המודל, ונתונות לאותה אי-ודאות שאותה הן אמורות לרסן.
- **רכזו את קריאות הטולים לנקודת יציאה אחת.** בלי Gateway אין נקודה אחת לאכוף בה, וכל טול חדש הוא חור אבטחה חדש. זו החלטה ארכיטקטונית שצריך לקבל לפני שיש עשרים טולים.

- **הפרידו את הרשאות הסוכן מהרשאות המשתמש.** זו ההצדקה המרכזית לאכיפה בשכבת הפוליסיו ולא בבקאנד. מערכת הליבה רואה זהות אחת; ה-Policy רואה שתיים.
- **כתבו חוקים ברמת הסשן, לא רק ברמת הבקשה.** הדמו הראה שחוק לכל בקשה נעקף בפיצול טריוויאלי. temporal policies הן התשובה, וכדאי להניח מראש שכל תקרה בודדת תיבדק לפיצול.
- **בדקו מה יש ב-trace לפני שמסתמכים עליו.** decision, policy, principal ו-latency הוצגו בדמו. זה הבסיס לכל דשבורד ולכל תשובה בביקורת.
- **אם מייצרים פוליסיו ב-GenAI — ולידציה ידנית חובה.** נאמר מפורשות מעל הבמה. חוק שנוסח לא נכון נאכף בדיוק כפי שנכתב.

מה לא נאמר

- לא הוצגו נתוני latency או מחיר של שכבת האכיפה מעבר למספר שהופיע ב-trace בודד על המסך.
- יכולות ה-Gateway שהוזכרו כקיימות — rate limit, semantic search של טולים, וכן Gateway Interceptors שמופיעים בתיאור הסשן — לא הודגמו.
- לא נאמרה זמינות כללית, אזורים נתמכים או מודל תמחור.
- בדיקת ה-Analyzable (automated reasoning על סתירות בחוקים) הופיעה על השקופית בלבד ולא הודגמה.

נספח: מונחים

מונח	מה זה	הופיע בסשן
Amazon Bedrock AgentCore	פלטפורמה מנוהלת להרצת סוכנים בפרודקשן. רכיביה (Runtime, Memory, Gateway, Identity, Policy, Observability) ניתנים לשימוש בנפרד	"אפשר להשתמש בקוביות האלה באופן אינדיפנדנט כמו לגו" [6:04]
AgentCore Gateway	נקודת כניסה יחידה לכל קריאות הטולים של הסוכן; עוטף targets מסוגים שונים ומציג אותם כטולי MCP	"דלת אחידה שדרכה האג'נט שלנו מדבר עם העולם החיצון" [6:04]
Target	טול שמחובר ל-Gateway. שלושה סוגים הוצגו: שרת MCP, OpenAPI ו-Lambda, schema	מסך ה-Gateway בקונסול [7:36]
AgentCore Policy	מנוע האכיפה שיושב בתוך ה-Gateway ומכריע allow/deny לכל קריאת טול	"כל קריאה שקורית מהאג'נט לטול עוברת דרך הפוליסיס" [9:10]
Policy engine	האובייקט שמאגד את כל הפוליסיוז ומשווה ל-Gateway במצב Enforced	"מאגד את כל הפוליסיס שיש לי במקום אחד" [9:10]
Cedar	שפת הפוליסיו שבה נכתבים החוקים. מבנה: forbid/permit + principal + action + resource + when	"קוראים לזה סידר" [9:10]
Principal	ה-WHO של הפוליסיו. באימות OAuth זהו טוקן JWT מלא, וכל claim בו הוא תנאי אפשרי	"כל שדה בטוקן הזה יכול להיות לתנאי פוטנציאלי" [10:42]
Temporal policy	פוליסיו שמצטבר על פני כל הסשן במקום להכריע לפי בקשה בודדת	"יודעים להסתכל ממש על session שלם" [19:55]
Dogwood	פרויקט קוד פתוח שמשולב עם Cedar ומספק את יכולת הצבירה לפי session ID	"פרויקט open source שנקרא דוגווד" [19:55]
Trace / Span	רשומת תצפיתיות ב-CloudWatch לכל מחזור חיים של בקשה; span הוא פעולה גרנולרית בתוכה	"כל spend זה בעצם פעולה גרנולרית" [21:26]
Strands	ה-framework שבו נכתב הסוכן בדמו	מופיע בשרטוט הארכיטקטורה וב-trace
Kiro	ה-agentic IDE של AWS, ששימש להדגמת חיבור ה-Gateway כשרת MCP	"קירו בי-the-way זה agentic IDE שיש לי-[7:36] AWS"