J. Inst. Electrostat. Jpn. 論 文

# 人工知能に基づいた除電特性適応イオナイザ

金 天海<sup>\*,1</sup>, 金田 優希<sup>\*</sup>, 久保 勝也<sup>\*</sup>, 高橋 克幸<sup>\*,\*\*</sup>, 高木 浩一<sup>\*,\*\*</sup>, 山口 晋一<sup>\*,\*\*\*</sup>, 永田 秀海<sup>\*\*\*</sup>

(2020年9月24日受付;2020年11月18日受理)

AI based Ionizer

Adaptive to Static-Electricity-Neutralization Characteristics Chyon Hae KIM<sup>\*,1</sup>, Yuki KANETA<sup>\*</sup>, Katsuya KUBO<sup>\*</sup>, Katsuyuki TAKAHASHI<sup>\*,\*\*</sup>, Koichi TAKAKI<sup>\*,\*\*</sup>, Shinichi YAMAGUCHI<sup>\*,\*\*\*</sup> and Hidemi NAGATA<sup>\*\*\*</sup> (Received September 24, 2020; Accepted November 18, 2020)

In this paper, we propose a static-electricity-neutralization-characteristic-adaptive ionizer equipped with a learning function for static-electricity-neutralization (SEN) characteristics by artificial intelligence in order to prevent the deterioration of the SEN speed due to the change in the SEN characteristic of AC corona discharge ionizer. The artificial intelligence of the proposed ionizer predicts the future electrical potential change of SEN target based on the information of the SEN target potential and the voltage duty applied to the ionizer electrode. The proposed ionizer controls the applied voltage duty based on the prediction result of the artificial intelligence. As a result of the experiment, the proposed ionizer reduced the static elimination by 63.2% or more as compared with the ionizer controlled by constant voltage and about 70.7% as compared with the ionizer controlled by PID control. In addition, an experiment was conducted in which the SEN characteristics of the ionizer were changed by limiting the peak of the voltage pulse. As a result, artificial intelligence quickly adapted to the new SEN characteristics and maintained shorter SEN time.

# 1. はじめに

電子機器の製造工程では、機器の誤作動や破壊・破損 につながる静電気放電や静電吸引の防止は必須であり<sup>1,2</sup>, 帯電物の帯電電荷を中和する除電装置としてイオナイザ が広く用いられている<sup>3,4</sup>.しかし、イオナイザの制御 規則は製造者の経験則により構成されることが多く、十 分な除電速度および残留電荷抑制効果を得ることが難し い場合も多い.特に、放電電極への塵の付着や劣化<sup>5,6</sup> によるイオン生成量の変化や、対象物と電極の距離、周 囲の温度・湿度、除電対象物の材料的変化などによる除

**キーワード**:除電,イオナイザ,人工知能,適応,予測 制御

- \* 岩手大学理工学研究科 (〒020-0066 岩手県盛岡市上田 4-3-5) The Graduate School of Science and Engineering, Iwate University, 4-3-5 Ueda, Morioka, Iwate 020-0066, Japan. \*\* 岩手大学次世代アグリイノベーションセンター
- (〒020-8550 岩手県盛岡市上田 3-18-8) Agri-Innovation Center, Iwate University, 3-18-8 Ueda, Morioka, Iwate 020-8550, Japan.
- \*\*\* シシド静電気株式会社 (〒100-6309 東京都千代田区丸の内2-4-19階918区) Shishido Electrostatic, Ltd. Marunouchi 2-4-19F 918-ku, Chiyoda, Tokyo 100-6309, Japan.
  - tenkai@iwate-u.ac.jp DOI : https://doi.org/10.34342/iesj.2021.45.1.8

電特性変化に対応して,状況に応じた適切な制御規則を 適用することは困難である.そこで本稿では,人工知能 による除電特性学習機能を備えた除電特性適応イオナイ ザを提案する.

イオナイザの制御方法としては、後に述べる Duty 比によ る方法や PID 制御による方法"などが考えられる。しかし ながら、これらの手法では除電時間と除電精度がトレード オフの関係となり、正確に素早い除電を行うことが難しい.

このトレードオフを解消するための手法として,モデ ル予測制御が提案されている<sup>8,9)</sup>.モデル予測制御は制 御対象物振る舞いを多数シミュレーションすることで最 適な制御入力を選択する手法であり,正確なシミュレー タ(モデル)が利用できる環境<sup>10)</sup>においては,除電時 間と除電精度の両立が期待できる.しかしながら,本稿 が課題とするイオナイザの制御では,「除電特性が変化 した場合にはシミュレータを再構築しなければならな い」という問題が発生するため,イオナイザへのモデル 予測制御の適用は難しかった.イオナイザのモデルを数 式化する場合<sup>11,12)</sup>には,数式のパラメータを逐次的に実 機周辺の現象に合わせ込むことが難しい.

そこで本研究では、上記シミュレータの再構築を人工 知能により自動化することで、除電特性が変化した際に も効果的なモデル予測制御を実行可能とした.これによ り、除電時間と除電精度の両立を達成した.

#### 2. 提案装置

図1に提案装置の概略図,図2に実験装置の外観を示 す.タングステン製の針(長さ:16 mm,半径:0.75 mm, テーパ角:20°,曲率半径:0.075 mm)を高圧電極に, ステンレス製のリング(内径:12.585 mm,外形:12.975 mm)を接地電極に用いた.針の先端はリング電極の中 心に設置した.交流電源には高圧アンプ(Trek, Model 20/20C-HS)を用いた.針の後方には,エアノズル(い けうち,1/4MTF-R8-010PP-IN)を設置し,圧縮空気を注 入することによって針前方に送風した.電極前方にイオ ン計測回路を接続したイオン捕集プレートを設置して電 位変化データを取得した.イオン捕集プレートはステン レス製の金属板(150×150 mm<sup>2</sup>)を用いた<sup>15)</sup>.

計測回路は、コンデンサ C1 (WIMA、FKP2-33/1000/10, 3直列, 33 pF)、C2 (KEMET、PHE448SB4100JR06, 1 nF)、 オペアンプ (Texas Instruments, OPA454) を用いたバッ ファ回路で構成した.イオン捕集プレート電位は、C1, C2 により分圧される.そこで、C2 の電位を、バッファ 回路を用いて測定することにより、イオン捕集プレート の電位を測定する.バッファ回路の出力電圧は、イオン 捕集プレートの電位の 85 分の 1 となる.バッファ回路 の出力電圧を A/D 変換して Raspberry Pi (マイクロコン



Fig.1 Schematic of Proposed Device.



Air nozzle Needle electrode

図2 提案装置外観

Fig.2 Appearance of Proposed Device.

ピュータ, Raspberry Pi 3 Model B+) に入力することで印 加電圧の Duty (図3参照) およびプレート電位を取得し た. また, RaspberryPi からの制御信号を ATmega1284P (マイクロコンピュータ) に入力することで、イオナイ ザの放電電極の印加電圧値を制御した. イオン捕集プレ ートと接地間の容量は、C1、C2の静電容量および配線の 合成容量となり 21.8 pF である. 放電に用いる針電極とイ オン捕集プレート間の距離は100 mm とした。また、針 電極に高電圧を印加した際に生じる静電誘導を除去する ために、99kΩの抵抗と計測回路をそれぞれ介して接地に 接続した2本の金属棒(真鍮,長さ:100 mm)を,高圧 アンプの近傍に設置した.これにより, 99 kΩの抵抗で は接地電極に流れ込む放電電流に重畳する静電誘導を, 計測回路では、取得される除電波形に重畳する静電誘導 を取得して、静電誘導を除去する。除電時間の測定には、 直流電源(シシド静電気、スタチラー35S)を用いた。

本装置の制御では,図4に示すように,装置の応答が 式(1)に従うと仮定する.

$$V(t+\Delta t) = f(D(t+\Delta t), V(t))$$
(1)

ただし、 $D(t+\Delta t)$ は時刻  $[t,t+\Delta t]$  における入力電圧 Duty, V(t)は現在のプレート電位、 $V(t+\Delta t)$ は $V(t+\Delta t)$ の印加を終えた時点  $(t+\Delta t)$  におけるプレート電位で あり、fは装置の除電特性に対応する関数である.

本制御では,関数fを人工知能 Dynamics Learning Tree  $(DLT)^{13}$ に学習させた. DLT は金属整形過程を模擬した



図3 Dutyと印加電圧の関係

Fig.3 Relationship of Duty and Applied Voltage. Duty は印加電圧(-4000Vまたは4000V)の割合を決定する 値であり, Duty = 1 では常に4000V, Duty = 0 では常に-4000V の印加電圧となる、本稿では、印加電圧パルス波の周期を1 kHzとして実験を行った。



図4 制御上の仮定

Fig.4 Assumption on Control.

人工知能であり、学習対象の関数の表面形状を金属表面 形状とのアナロジーに基づいて整形するアルゴリズムで ある.ニューラルネットワークなど、多くの人工知能では 忘却<sup>14)</sup>と適応のバランス調整ができないのに対し、DLT はその問題を数学的に解決しており、定数オーダ O(1)で のオンライン学習処理を安定的に行うことができる.

制御に用いる前に、人工知能には学習処理を行う. この処理は、装置から観測したV(t), $V(t+\Delta t)$ ,および  $D(t+\Delta t)$ の組を多数用いて人工知能に関数fの推定関数 fを生成させる処理である.DLTの場合には、この処理 は自動化されており、上記のデータを与える毎に推定関 数fが更新され、関数fへと近づく.

人工知能により制御を行う際には、まず、現在時刻に おいて計測した電位 V(t) と投入可能な *i* 種の Duty  $D_i$  $(t+\Delta t)$ の情報を人工知能が持つ関数 *f* に代入し、将来の 制御対象物電位  $V(t+\Delta t)$ の予測値 $\hat{V}_i(t+\Delta t)$ を得る.次に、 最も0に近い  $\hat{V}_i(t+\Delta t)$  を与える $D_i(t+\Delta t)$ を下式のよう に選択し、これを最適制御値 $D(t+\Delta t) = D^*(t+\Delta t)$ として 電源制御ユニット(図5)へ送信する.

$$D^{*}(t+\Delta t) = \underset{D_{i}(t+\Delta t)}{\operatorname{argmin}} |\hat{V}_{i}(t+\Delta t)|$$
(2)

電源制御ユニットは、与えられた制御値 D(t+Δt)に従った Duty を高電圧電源に与える.高電圧電源はその Duty に従ってコロナ放電電極の電圧調整を行う.この 電圧によりコロナ放電電極で発生したイオンはエアノズ ルにて除電対象物へと到達する.

#### 3. 実験

提案装置の効果を確認するため以下の実験を行った.

#### 3.1 電位予測に関する実験

DLT による電位予測を実際の制御対象物の電位と比較 することで、DLT の予測精度を検証した.

本実験で DLT に学習させたデータは、提案装置より Duty 値を一定として取得しており、*D*=0.1×*n*(n=1,2, …,10)の10通りおよび初期プレート電位*V*(0)=-1000 or 1000の2通りの計20通りの駆動条件からサンプリング した 6400 データ(51.2秒分)である.

図6は、DLT が予測したプレート電位と、その後実機 から得られた電位の比較である.DLT は実機の結果を再 現している.DLT の予測誤差を表1に示す.DLT は、 未学習の Duty に対して予測を行う際に、学習済のデー タからの補完を行うため、学習済 Duty の結果の方が若 干良い値となり易い.本実験も同様の結果となっており、 未学習 Duty に対する誤差は学習データを増やすことで さらに改善すると考えられる.



図5 イオン制御フロー Fig.5 Ion-Control Flow.



図6 予測プレート電位

Fig.6 Predicted Plate Voltage.

表 1	予測誤差
10.1	J 189U/1/T.

Table 1 Prediction Error.

DLT の学習不足に起因する学習誤差は、平均予測誤差について、未学習の値から学習済の値を差し引くことで得られる.

学和这下, 1200 2102	
子首済 Duty 1.328 2.103	
未学習 Duty 3.098 3.230	

1 Step = 8 ms

予測値は,時刻 0s 時点のプレート電位と Duty の値を DLT に入力して時刻 0s 時点で得た将来予測の値.測定 値はその後駆動中の実機から得られた値.本図では 250 ms 分の予測結果を示したが,制御には 8 ms 分の予測の みを用いた.

## 3.2 制御効果に関する実験

提案装置を多くのイオナイザで用いられている慣習法や 従来法である PID 制御と比較するための実験を行った.

本実験では,提案装置の制御には 3-1節の実験で学習 させた DLT を用いた. DLT による制御に対する比較対 象として, Duty を一定として制御する慣習法 1, プレー ト電位が 0 となった瞬間に Duty を切り替える慣習法 2, および PID 制御を用意した. 慣習法 1 は工業製品とし て最もよく使用されている手法である. また, PID 制御 のゲインは事前に調整し, P ゲイン=0.05, I ゲイン=0.1, D ゲイン=0.00015 とした.

図7および図8に提案法と慣習法1の比較結果を示す. 慣習法1ではDuty値が固定であるため,短時間で正確 に電圧を0に制御することが難しい.本実験でも,素早 い除電を行うDuty(0.05 や 0.95)では行き過ぎが発生 した.また,行き過ぎを発生させずに正確に0に近づく ようなDuty(0.52 や 0.56)では提案法と比べて除電に 時間がかかっている.これに対して,提案法では,DLT の将来電位予測に従って各時刻に適切なDutyを選択し 直す.実験の結果からも素早くかつ正確に電位を0へと 収束させることができたことが分かる.

図9および図10に提案法と慣習法2の比較結果を示 す. 慣習法2では、プレート電位が0となった時点で Dutyを切り替えるため、慣習法1(図7のDuty=0.95や 図8のDuty=0.05)ほどの行き過ぎは生じない.しかし ながら、Duty切り替えタイミングが最適なタイミング よりも遅れるため、その遅れの分だけ行き過ぎが発生す る.Duty切り替え後には、ここで発生した行き過ぎを 補正するために長い時間を要する.本実験においても慣 習法2は行き過ぎを発生させており、提案法の方が早く 正確に電位を制御できていることが分かる.特に、DLT の予測(図9および図10のPrediction)を見ると、DLTは、 プレート電位が0に到達するよりも前の時刻に電位が0 へと到達するタイミングを正確に予測していることが分 かる.

表2に提案法と慣習法2の除電時間を示す.初期プレート電位(1000Vまたは-1000V)が1/100に減衰(10V または-10V)するまでの時間を尺度に比較した結果, 提案法は慣習法2と比較して63.2%以上の除電時間削減 効果を示した.



図7 提案法と慣習法1の比較(負帯電)

Fig.7 Comparison of Proposed Method and Conventional Method 1 (Negative Charge).



図8 提案法と慣習法1の比較(正帯電)

Fig.8 Comparison of Proposed Method and Conventional Method 1 (Positive Charge).



図9 提案法と慣習法2の比較(負帯電)

Fig.9 Comparison of Proposed Method and Conventional Method 2 (Negative Charge).



図10 提案法と慣習法2の比較(正帯電)

Fig.10 Comparison of Proposed Method and Conventional Method 2 (Positive Charge).

表2 提案法と慣習法2の除電時間

 
 Table
 2 Neutralization Time of Proposed Method and Conventional Method 2.

	正帯電	負帯電
提案法	0.240 s	0.256 s
慣習法 2	0.736 s	0.696 s
時間削減率	67.4%	63.2%



図 11 提案法と PID 制御の比較

Fig.11 Comparison of Proposed Method and PID Control.

表3	提	案法と PID 制御の除電時間
Table	3	Neutralization Time of Proposed
		Method and PID Control.

	·
提案法	0.232 s
PID 制御	0.792 s
時間削減率	70.7%

図 11 に提案法と PID 制御の比較結果を示す. PID 制 御はパラメータである P ゲイン, I ゲイン, D ゲインを 調整することにより収束時間の短縮や収束精度向上が可 能であるが, それら 2 つはトレードオフの関係となり両 立は難しい.本実験では, 電圧が 0 へと収束するパラメ ータのうちなるべく早く収束するものを試行錯誤で選択 して実験を行ったが,提案法のような素早く正確な収束 は見られなかった.

表3に提案法とPID 制御の除電時間を示す. 慣習法2 との比較と同様に1/100に減衰するまでの時間を尺度に 比較した結果,提案法はPID 制御と比較して70.7%の除 電時間削減効果を示した.

#### 3.3 除電特性変化への適応実験

提案装置が装置自体の除電特性変化に対して適応でき るか,および短い除電時間を維持できるかを調べるため の実験を行った.

本実験では、提案装置の電極劣化による除電特性変化 を模擬するために、電極への最大印加電圧を意図的に抑 制することとした.イオナイザへの最大印加電圧(3.5kV-4.5kV)に従って、制御対象物上での除電特性は図12に 示すように様々に変化する.

本実験では、V(t)、V(t+Δt),およびD(t+Δt)の組を1 データ対として、約1秒分のデータに相当する100デー タ対を1データセットとした.図12に示す異なる6つ の最大印加電圧に対して各1データセット、計6データ セットをDLTの学習用に準備した(学習データセット). さらに学習用とは別の6データセットをDLTの予測精 度検証用に準備した(検証データセット).

図 13 に DLT の学習結果を示す. 6つの学習データセットを順に学習させると, 100 データ毎に最大印加電圧







図13 除電特性の変化と絶対予測誤差

Fig.13 Switches of Neutralization Characteristics and Absolute Prediction Error.

**DLT** が 100 データ対学習する毎に,最大印加電圧を変化させた. α の値は **DLT** の忘却率.

の異なるデータを学習することになるため、一時的な予 測誤差上昇が見られたが、学習の進行とともに誤差は速 やかに低下した.提案装置は除電特性の変化に速やかに 適応したことが分かる.

## 3.4 適応と除電効果に関する実験

提案装置が除電特性変化に適応する際に,除電効果が どのように遷移するかを試験した.

本実験では, DLT に事前に最大印加電圧 4.5 kV の条件 で 100 データ対学習させた. この DLT に最大印加電圧 4.3 kV の条件で取得した 1, 3, 5, 10 データ対をそれぞ れ追加で学習した場合について, 3-1 節と同様の実験を 行い, 除電対象物であるプレートの電位の減衰時間を調 べた. この際の最大印加電圧は 4.3 kV とした.

図 14 にプレート電位の減衰の様子を示す.最大印加 電圧 4.3 kV において学習したデータ数が1,3,5,10 と 増加するに従い,プレート電位が0 V へと収束するまで の時間が短くなっていることが分かる.いずれの場合に も最終的には0 V へと収束している.

表4にプレート電位が1/100に減衰するまでの時間を



図14 適応の進行と除電効果

Fig.14 Progress of Adaptation and Effectiveness of Neutralization.

表 4 適応の進行と除電時間 Table 4 Progress of Adaptation and Neutralization Time.				
学習データ数	除電時間[s]			
1	0.456			
3	0.334			
5	0.336			
10	0.264			

基準とした除電時間を示す. 学習データの増加に伴って, 除電時間はほぼ単調に減少していることが分かる.

#### 4. 考察

#### 4.1 除電時間に関する考察

3.2節の実験より, Duty を一定として制御する慣習法 1や PID 制御では, Duty を大きくすると行き過ぎが発生 し,小さくすると除電時間が長くなるため,除電時間削 減において限界があることが分かる.一方で,プレート 電位が0に到達した際に Duty を切り替える慣習法2で は,Duty 切り替えタイミングの遅れが行き過ぎを誘発 し,行き過ぎ分の電位が収束するまでに時間がかかるこ とが分かる.Duty 切り替えタイミングを適切に調整す るためには,プレート電位が0に到達するタイミングを 前もって予測しなければならないため,何らかの予測機 能が必要である.DLT はその予測機能を担保しているた め,比較的早い除電時間を実現したと考えられる.

#### 4.2 DLTの学習および適応に関する考察

DLT が持つ除電特性を逐次的に学習する機能は,除電 特性が変化した際にも4.1節の予測機能を担保するため に有効である.3.3節の実験より,除電特性変化が起き てからしばらくすると DLT の予測精度はほぼ除電特性 変化前と同等の値に改善した.3.4節の実験において, 学習データ数10まで学習を終えた DLT は,0.264s で除 電を終えており,3.2節や3.3節において DLT を十分に 学習させた場合の結果(表2:0.240s,0.256s,表3:0.232s) に近いところまで回復してきている. 学習に必要なサン プルデータを 10 データ対集めるにはおよそ 80ms だけ 実機を稼働させれば良いため, DLT はリアルタイムな学 習を通じて予測機能を復帰させるのに十分な学習速度を 示したといえる.

# 4.3 計算コスト

今回実験に用いた慣習法 1, 慣習法 2, PID 制御, およ び提案法のいずれも RaspberryPi 上において 8 ms の制御 周期を実現することができた. ただし, 慣習法 1, 慣習 法 2, および PID 制御の計算コストは個々のパラメータ の設定に対して一定であるのに対し, 提案法の計算コス トは, 予測に用いる Duty 値  $D_i(t+\Delta t)$ の候補数 i に比例 して増大するため, 計算機の性能に応じて i の値を調整 することが必須となる. 一般的には候補は多いほど良い ため, 計算が制御周期に間に合う範囲で最大値をとるの が望ましい.

#### 4.4 フィードバック制御と提案法

人工知能を用いない通常のフィードバック制御では, 除電特性が変化した場合の適応に限界がある. PID 制御 などを含む通常のフィードバック制御では,式(1)の関 数fを1種に固定するため,当該関数で対応ができない ような除電特性変化が生じた場合には効果的な制御がで きない.提案法の場合には,関数fを人工知能が獲得す るため,通常のフィードバック制御よりも多様な除電特 性変化に対応できる.ただし,いずれの場合にも実機の 応答が式(1)で近似できることを前提としているため, この仮定が成り立たないような除電特性変化には対応が できない.よって,さらに多様な除電特性変化に対応で きる制御を構成しようとするならば,式(1)に相当する ような応答モデル自体を人工知能に構成させるのが良い だろう.

#### 5. おわりに

本稿では、交流コロナ放電イオナイザにおける除電特 性変化に着目し、AIを活用して除電特性変化に適応す る除電特性適応イオナイザを提案した.提案したイオナ イザは定電圧制御によるイオナイザ等と比較して 63.2% 以上、PID 制御によるイオナイザと比較して約 70.7%の 除電時間を短縮した.また、提案装置は除電特性が変化 した際にも適応し、学習データ数の増加に従って除電時 間を短縮することができた.これにより、除電特性変化 に頑健なイオナイザの構成論が明らかとなった.

一方で、今回得られた結果のみでは人工知能の判断や 振る舞いについての解析は困難であり、今後調査・検討 すべき課題として残されている。

#### 参考文献

- 1) 辻 幹生:LSI 製造における静電気問題と対策. 静電気 学会誌, 19 (1995) 28
- 2) 萩原良昭: DRAM/SPAM 技術と静電気. 静電気学会誌, 22 (1998) 277
- 村田雄司:除電装置と除電技術、シーエムシー出版 (2004)
- K. Takahashi, K. Takaki, I. Hiyoshi, Y. Enomoto, S. Yamaguchi and H. Nagata: Modern Applications of Electrostatics and Dielectrics, p. 472, IntechOpen Ltd., London, (2019)
- 5) 佐藤朋且, 鈴木政典, 水野 彰: 電極加熱による低発塵 コロナ放電式イオナイザーの開発. 静電気学会誌, 37 (2013) 215
- 6) 吉水健剛,池畑 隆,岩本菜夏,岡野一雄:ACイオナイザの周波数が除電能力に及ぼす影響.静電気学会誌, 36 (2012) 297
- 7) 綿野 哲, 斎藤誠司, 鈴木輝夫:空気輸送プロセスにお ける粒子帯電のフィードバック制御. 粉体工学会誌, 39 (2002) 496
- S. J. Qin and T. A. Badgwell: A survey of industrial model predictive control technology. Control Eng. Pract. 11 (2003) 733

- A. Grancharova, J. Kocijan and T. A. Johansen: Explicit output-feedback nonlinear predictive control based on blackbox models. Eng. Applic. Artific. Intell. 24 (2011) 388
- 10) C. H. Kim and S. Sugano: Tree Based Trajectory Optimization Based on Local Linearity of Continuous Non-Linear Dynamics. IEEE Trans. on Automatic Control 61, (2016) 2610
- J.-S. Chang: Neutralization Theory of Static Surface Charges by an Ionizer under Wide Gas Pressure Environments. IEEE Trans. on Industry Applic. 37 (2001) 1641
- A. Ohsawa: Modeling of Charge Neutrization by Ionizer. Journal of Electrostatistics, 63 (2005) 767
- 13)金 天海:ロボティクスシンポジア予稿集.4C4,日本ロ ボット学会,日本機械学会,計測自動制御学会(2018)
- R. M. French: Catastrophic forgetting in connectionist networks, Trends in Cognitive Science, 3 (1999) 128
- 15) K. Takahashi, H. Kaga, K. Kubo, K. Takaki, S. Yamaguchi and H. Nagata: Development of an ion measuring system for AC corona discharge. IEEJ Trans. on Fundamentals and Materials, Letter, **138** (2018) 551